

**ANDREA TEDESCO**

**DELIMITAÇÃO DE VOÇOROCA COM IMAGENS DE ALTA  
RESOLUÇÃO E ALS POR MEIO DE ÁRVORE DE DECISÃO E  
GEOBIA**

**Curitiba  
2015**

**ANDREA TEDESCO**

**DELIMITAÇÃO DE VOÇOROCA COM IMAGENS DE ALTA  
RESOLUÇÃO E ALS POR MEIO DE ÁRVORE DE DECISÃO E  
GEOBIA**

Tese apresentada ao Curso de Pós- Graduação em Ciências Geodésicas, Departamento de Geomática, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Dr. Alzir Felipe Buffara Antunes

**Curitiba  
2015**

---

T256d

Tedesco, Andrea

Delimitação de voçoroca com imagens de alta resolução e ALS por meio de árvore de decisão e geobias/ Andrea Tedesco. – Curitiba, 2015.  
186 f. : il. color. ; 30 cm.

Tese - Universidade Federal do Paraná, Setor de Ciências da Terra,  
Programa de Pós-graduação em Ciências Geodésicas, 2015.

Orientador: Alzir Felipe Buffara Antunes .  
Bibliografia: p. 167-179.

1. Voçorocas - Classificação. 2. Métodos orientados a objeto  
(Computação). 3. Processamento de imagens. 4. Árvores de decisão. I.  
Universidade Federal do Paraná. II. Antunes, Alzir Felipe Buffara. III. Título.

CDD: 551.305

---

## TERMO DE APROVAÇÃO

ANDREA TEDESCO


“DELIMITAÇÃO DE VOÇOROCA COM IMAGENS DE ALTA RESOLUÇÃO E ALS  
POR MEIO DE ÁRVORE DE DECISÃO E GEOBIA”

Tese nº 96 aprovada como requisito parcial do grau de Doutor no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:




Prof. Dr. Alzir Felipe Buffara Antunes  
Departamento de Geomática, UFPR



Profª. Drª. Christel Lingnau  
Departamento de Ciências Florestais, UFPR



Prof. Dr. Hideo Araki  
Departamento de Geomática, UFPR



Prof. Dr. Quintino Dalmolin  
Universidade Federal do Paraná, UFPR



Prof. Dr. Jorge Antonio Silva Centeno  
Departamento de Geomática, UFPR

Curitiba, 30 de julho de 2015.



Dedico a Emma Gebauer, *in memoriam*.

## AGRADECIMENTOS

A realização desta pesquisa só foi possível com o apoio de algumas instituições e pessoas, algumas às quais, de forma especial, agradeço:

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela concessão de bolsa de estudos.

Ao curso de pós-graduação em Ciências Geodésicas da Universidade Federal do Paraná – UFPR. Especialmente à secretária Veraly *Mônica* Kleuser e aos professores do curso, os quais me transmitiram, desde a graduação, muito do conhecimento que hoje tenho.

À Universidade Estadual de Ponta Grossa – UEPG, pela concessão de licença integral durante a realização do doutorado. Ao Departamento de Geociências e ao programa de pós-graduação em Gestão do Território, os quais possibilitaram a realização do trabalho de campo em Uberlândia-MG, junto à Universidade Federal de Uberlândia.

Ao Centro de Sensoriamento Remoto da divisão de Ciências do Departamento de Ciências, Tecnologia da Informação, Inovação e Artes do Governo de Queensland – Austrália, na pessoa do senhor Dan Tindall, pela cessão dos dados referentes à área de estudo localizada em Queensland.

À empresa Engesat Imagens de Satélite Ltda, na pessoa da senhora Jaqueline Cavalli, pela cessão da imagem Ikonos da cidade de Uberlândia-MG.

À Esteio Engenharia e Aerolevantamentos S.A., na pessoa da senhora Elizabete Bugalski de Andrade Peixoto, pela cessão dos dados de perfilamento a LASER da cidade de Uberlândia-MG.

Ao meu orientador, professor Dr. Alzir Felipe Buffara Antunes, agradeço por ter aceitado orientar essa pesquisa, pela divisão de conhecimentos, paciência e cordialidade.

Aos professores Dr. Hideo Araki e Dr. Jorge Antonio Silva Centeno, por terem me orientado em momentos distintos do doutorado e por, junto com o Dr. Alzir, terem

sido meus mestres de sensoriamento remoto, desde a graduação, e influenciado minha paixão pelo tema.

Ao meu marido Marcelo Barreto, meu amor imensurável, meu companheiro inigualável, por todo amparo, apoio, paciência, auxílio e motivação.

À minha família, pelo amor incondicional, pelo suporte, pela paciência, pela confiança, por serem meu porto seguro, fontes das mais belas e puras energias.

Às minhas famílias Barreto, Gaase e Moraes que, apesar de não serem consanguíneas, expressam os mesmos laços de amor.

Ao amigo-irmão Geraldo Santos Landovsky, pela amizade incondicional e eterna, pelo amparo emocional e pela sempre inexaurível motivação.

À amiga e colega de trabalho Profa. Dra. Maria Lígia Cassol Pinto por “apresentar-me” às voçorocas e por contagiar-me com sua paixão pelo tema.

Aos terapeutas Arceni José Dalmoro, Cristina Santos, Fernanda Cidral e Maximiano Reis, por auxiliarem-me na busca do autoconhecimento, autocontrole e equilíbrio psicoemocional.

Ao Luiz Octávio Olini, “irmão” de orientação, pelo auxílio no início do trabalho com o eCognition.

Aos colegas do programa de pós-graduação que se tornaram amigos: Alice Marinho Etienne, Andrey Augusto Alves de Oliveira, Camila Zonta Caldas, Carla Casaroti, João Henrique Becker, Karina de Souza Silva Rios, Luciana Maria da Silva, Lucía Verónica Jaramillo Toledo, Marly Terezinha Quadri Simões da Silva, Nerio Aparecido Cardoso, Rafael Mohl de Sousa e Renata Magda Cavalcanti Werlich.

Aos colegas do laboratório de sensoriamento remoto: Felipe Martins Marques da Silva, Gabriel Henrique de Almeida Pereira e Jair Jacomo Bertucini Júnior.

“Na verdade, a gente tem que pensar que o solo é um patrimônio da humanidade, que ele é finito. Eu não consigo fazer solo. Eu até consigo fazer celular, computador, carro, mas solo eu não consigo. Solo é um patrimônio da humanidade que é extremamente importante para a alimentação da nossa geração e das gerações futuras. Manter os recursos naturais para as próximas gerações é um dever nosso, de todos os dias.”

Sérgio Alves

## RESUMO

As voçorocas representam os processos erosivos responsáveis pelos maiores prejuízos ambientais, sociais e financeiros. A aplicação de medidas corretivas e preventivas necessita do mapeamento das voçorocas, bem como do monitoramento de sua evolução. No âmbito do sensoriamento remoto, dentre as características das voçorocas, podem-se citar: heterogeneidade espectral (mistura de solo, vegetação, sombra e água), heterogeneidade espacial (existência de feições como cabeceira, canais e dígitos, com formas irregulares e dimensões variáveis) e variação altimétrica (com alta declividade nas bordas). Em função destas especificidades, este estudo propôs uma metodologia para delimitação de voçorocas, em procedimentos de classificação de imagens baseados em análise orientada a objeto. Para tal, foram usadas imagem e ortofoto de alta resolução espacial e dados altimétricos ALS. Duas áreas de estudo foram selecionadas: uma localizada em Uberlândia-MG e outra localizada em Queensland-Austrália. Os objetos foram gerados por segmentação multirresolução (método FNEA-*Fractal Net Evolution Approach*). Foram selecionados os atributos mais relevantes na delimitação das voçorocas, usando algoritmos de indução de árvores de decisão (CART - *Classification And Regression Trees*), sendo estes atributos espectrais, altimétricos e de textura. Foram realizadas classificações por árvores de decisão e por classificação hierárquica. O uso da árvore de decisão permitiu a seleção de atributos e o estabelecimento de uma base de regras de decisão preliminar para a delimitação da voçoroca. Entretanto, como esse tipo de procedimento não faz uso de lógica fuzzy, as misturas entre as classes não pode ser evidenciada na base de regras de decisão. Além disso, a classificação é realizada apenas para um fator de escala, não permitindo identificar todas as feições constituintes do sistema voçoroca (como canais e dígitos). Na classificação hierárquica, o procedimento é realizado em escalas diferentes, permitindo o uso da lógica fuzzy para descrever diferentes graus de pertinência a cada classe, o que torna o método bastante atraente para casos como o deste estudo, onde há mistura de classes. Assim, a classificação obtida com o método semiautomático, de classificação hierárquica, mostrou-se mais fidedigna à realidade de campo, por permitir o uso de escalas diferentes, inserção de incerteza (pela lógica fuzzy) e inserção de conhecimento (pela base de regras estabelecida), quando comparada à classificação automática por árvore de decisão.

Palavras-chave: voçoroca, análise orientada a objeto, segmentação multirresolução, classificação hierárquica, árvores de decisão.

## **ABSTRACT**

The gullies represent the erosive processes responsible for major ambient, social and financial damages. The application of corrective and preventive measures needs to map gullies, as well as the monitoring of its evolution. Under remote sensing, the characteristics of the gullies can be mentioned: spectral heterogeneity (soil, vegetation, shade and water mix), spatial heterogeneity (existence of features as head, canals and digits with irregular forms and variable dimensions) and altimetry variation (with high declivity on the borders). Due to these specificities, this study proposed a methodology for delimitation of gullies on image classification procedures based on object-oriented image analysis. For such, there were used high spatial resolution image and orthophoto and ALS altimetry data. Two study areas were selected: one located in Uberlandia, Minas Gerais and another located in Queensland, Australia. The objects were generated by multiresolution segmentation (FNEA-Fractal Net Evolution Approach method). The most important attributes in the definition of gullies were selected using decision tree induction algorithms (CART - Classification and Regression Trees), being these attributes spectral, altimetry and texture. Classifications by decision trees and hierarchical were carried out. The use of decision tree allowed the selection of attributes and the establishment of preliminary decision rules as a basis for the delimitation of the gully. However, since this procedure does not use fuzzy logic, mixtures between classes cannot be evidenced in the rule base. Moreover, the classification is performed only by a factor of scale, allowing the identification of all the constituent features of the gully system (such as channels and digits). In hierarchical classification, the procedure is performed at different scales, allowing the use of fuzzy logic to describe different degrees of membership in each class, which makes it a very attractive method for cases such as this study, where there is mixing of classes. Thus, the classification obtained with the semi-automatic method of hierarchical classification, proved the field of reality more reliable, by allowing the use of different scales, uncertainty insert (by fuzzy logic) and integration of knowledge (the established rule base) compared to the automatic classification by decision tree.

**Keywords:** gully erosion, object based image analysis, multiresolution segmentation, hierarchical classification, tree decision.

## LISTA DE ILUSTRAÇÕES

### FIGURAS:

FIGURA 1 – TIPOS DE EROSÃO.....	22
FIGURA 2 – FORMAÇÃO DOS PROCESSOS EROSIVOS DE ORIGEM HÍDRICA.....	27
FIGURA 3 – VOÇOROCAS DE GRANDES DIMENSÕES.....	30
FIGURA 4 – IMAGEM DE INTENSIDADE ALS E DA BANDA NIR - IKONOS.....	33
FIGURA 5 – ESTAQUEAMENTO PARA MONITORAMENTO DE VOÇOROCA.....	35
FIGURA 6 – LOCALIZAÇÃO DA ÁREA DE ESTUDO A1.....	48
FIGURA 7 – DIRECIONAMENTO DOS REGISTROS FOTOGRÁFICOS, CANAIS E DIMENSÕES DA VOÇOROCA.....	49
FIGURA 8 – REGISTROS FOTOGRÁFICOS DA ÁREA DE ESTUDO A1.....	50
FIGURA 9 – LOCALIZAÇÃO DA ÁREA DE ESTUDO A2.....	53
FIGURA 10 – DIAGRAMA COM AS ETAPAS METODOLÓGICAS.....	57
FIGURA 11 – DIAGRAMA DO PRÉ-PROCESSAMENTO DOS DADOS.....	58
FIGURA 12 – CARACTERÍSTICAS DO FILTRO ATIN.....	63
FIGURA 13 – IMAGEM DA BANDA DO VERMELHO E IMAGEM DE INTENSIDADE ALS.....	66
FIGURA 14 – CURVAS TÍPICAS DA REFLECTÂNCIA ESPECTRAL DA ÁGUA, SOLO E VEGETAÇÃO.....	67
FIGURA 15 – SEGMENTAÇÃO DE IMAGEM.....	69
FIGURA 16 – PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO.....	74
FIGURA 17 – OBJETOS-IMAGEM RESULTANTES DA SEGMENTAÇÃO EM DIFERENTES ESCALAS.....	77
FIGURA 18 – REDE HIERÁRQUICA DE OBJETOS-IMAGEM E SUAS RELAÇÕES TOPOLÓGICAS.....	78
FIGURA 19 – ÁREAS DE OCLUSÃO NOS DADOS ALS.....	80
FIGURA 20 – CARACTERÍSTICAS DOS OBJETOS-IMAGEM.....	83
FIGURA 21 – CARACTERÍSTICAS ESPECTRAIS DOS OBJETOS-IMAGEM.....	84
FIGURA 22 – CARACTERÍSTICAS GEOMÉTRICAS.....	87
FIGURA 23 – REPRESENTAÇÃO GRÁFICA DE UMA ÁRVORE DE DECISÃO.....	92
FIGURA 24 – ARQUITETURA BÁSICA DE UM SISTEMA FUZZY.....	103
FIGURA 25 – FUNÇÕES DE PERTINÊNCIA FUZZY DISPONÍVEIS NO PROGRAMA ECOGNITION.....	104
FIGURA 26 – IMAGEM DE INTENSIDADE DA ÁREA DE ESTUDO A1.....	112
FIGURA 27 – MODELO DIGITAL DE SUPERFÍCIE DA ÁREA DE ESTUDO A1.....	112
FIGURA 28 – MDTs OBTIDOS COM DIFERENTES FILTROS – ÁREA DE ESTUDO A1.....	114
FIGURA 29 – MODELO DIGITAL DE TERRENO DA ÁREA DE ESTUDO A1.....	115
FIGURA 30 – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO DA ÁREA DE ESTUDO A1.....	115
FIGURA 31 – MAPA DE CURVAS DE NÍVEL DA ÁREA DE ESTUDO A1.....	116
FIGURA 32 – MAPA DE DECLIVIDADE DA ÁREA DE ESTUDO A1.....	117
FIGURA 33 – IMAGEM NDVI DA ÁREA DE ESTUDO A1.....	118
FIGURA 34 – IMAGEM DE INTENSIDADE DA ÁREA DE ESTUDO A2.....	118
FIGURA 35 – MODELO DIGITAL DE SUPERFÍCIE DA ÁREA DE ESTUDO A2.....	119
FIGURA 36 – MODELO DIGITAL DE TERRENO DA ÁREA DE ESTUDO A2.....	120
FIGURA 37 – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO DA ÁREA DE ESTUDO A2.....	120
FIGURA 38 – MAPA DE CURVAS DE NÍVEL DA ÁREA DE ESTUDO A2.....	121
FIGURA 39 – MAPA DE DECLIVIDADE DA ÁREA DE ESTUDO A2.....	121
FIGURA 40 – IMAGEM ICBI DA ÁREA DE ESTUDO A2.....	122
FIGURA 41 – IMAGEM ICBI DA ÁREA DE ESTUDO A1.....	123
FIGURA 42 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=50 PARA ÁREA DE ESTUDO A1.....	125
FIGURA 43 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=50 PARA ÁREA DE ESTUDO A2.....	126
FIGURA 44 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=100 PARA ÁREA DE ESTUDO A1.....	127

FIGURA 45 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=100 PARA ÁREA DE ESTUDO A2.....	128
FIGURA 46 – AMOSTRAS PARA TREINAMENTO DA ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1.....	131
FIGURA 47 – ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1.....	132
FIGURA 48 – ATRIBUTOS SELECIONADOS NA MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A1.....	133
FIGURA 49 – CLASSIFICAÇÃO POR ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1.....	135
FIGURA 50 – AMOSTRAS PARA TREINAMENTO DA ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2.....	137
FIGURA 51 – ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2.....	137
FIGURA 52 – ATRIBUTOS SELECIONADOS NA MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A2.....	138
FIGURA 53 – CLASSIFICAÇÃO POR ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2.....	139
FIGURA 54 – REDE HIERÁRQUICA – ÁREA DE ESTUDO A1.....	141
FIGURA 55 – REDE HIERÁRQUICA – ÁREA DE ESTUDO A2.....	142
FIGURA 56 – REDE HIERÁRQUICA E ATRIBUTOS – ÁREA DE ESTUDO A1.....	144
FIGURA 57 – REDE HIERÁRQUICA E ATRIBUTOS – ÁREA DE ESTUDO A2.....	149
FIGURA 58 – CLASSIFICAÇÃO HIERÁRQUICA – ÁREA DE ESTUDO A1.....	153
FIGURA 59 – CLASSIFICAÇÃO HIERÁRQUICA – ÁREA DE ESTUDO A2.....	154
FIGURA 60 – DISTRIBUIÇÃO DAS AMOSTRAS DE VERIFICAÇÃO – ÁREA DE ESTUDO A1..	155
FIGURA 61 – DISTRIBUIÇÃO DAS AMOSTRAS DE VERIFICAÇÃO – ÁREA DE ESTUDO A2..	156
FIGURA 62 – CLASSIFICAÇÕES DA ÁREA DE ESTUDO A1.....	158
FIGURA 63 – CLASSIFICAÇÕES DA ÁREA DE ESTUDO A2.....	159

#### **QUADROS:**

QUADRO 1 – CARACTERÍSTICAS DO SENSOR IKONOS II.....	55
QUADRO 2 – CARACTERÍSTICAS DO SENSOR OPTTECH ALTM 2025.....	55
QUADRO 3 – CARACTERÍSTICAS DO SENSOR RIEGL LMS-Q560.....	56
QUADRO 4 – ATRIBUTOS SUBMETIDOS À MINERAÇÃO DE DADOS - ÁREA DE ESTUDO A1.....	100
QUADRO 5 – ATRIBUTOS SUBMETIDOS À MINERAÇÃO DE DADOS - ÁREA DE ESTUDO A2.....	100
QUADRO 6 – MATRIZ DE CONFUSÃO.....	109
QUADRO 7 – CHAVES DE INTERPRETAÇÃO – ÁREA DE ESTUDO A1.....	129
QUADRO 8 – CHAVES DE INTERPRETAÇÃO – ÁREA DE ESTUDO A2.....	130

#### **TABELAS:**

TABELA 1 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE TREINAMENTO (CLASSIF. POR ÁRVORE DE DECISÃO) – ÁREA DE ESTUDO A1.....	134
TABELA 2 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE TREINAMENTO (CLASSIF. POR ÁRVORE DE DECISÃO) – ÁREA DE ESTUDO A2.....	140
TABELA 3 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE VERIFICAÇÃO (CLASSIFICAÇÃO HIERÁRQUICA) – ÁREA DE ESTUDO A1.....	156
TABELA 4 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE VERIFICAÇÃO (CLASSIFICAÇÃO HIERÁRQUICA) – ÁREA DE ESTUDO A2.....	157



## LISTA DE SIGLAS E ABREVIATURAS

ALDPAT	- AIRBORNE LIDAR DATA PROCESSING AND ANALYSIS TOOLS
ALS	- AIRBORNE LASER SCANNING
ALTM	- AIRBORNE LASER TERRAIN MAPPER
ASTER	- ADVANCED SPACEBORNE THERMAL EMISSION AND REFLECTION RADIOMETER
ATIN	- ADAPTIVE TIN FILTER
CAPES	- COORDENAÇÃO DE APERFEIÇOAMENTO DE PESSOAL DE NÍVEL SUPERIOR
CART	- CLASSIFICATION AND REGRESSION TREE
CBERS	- CHINA-BRAZIL EARTH RESOURCES SATELLITE
CHAID	- CHI-SQUARE AUTOMATIC INTERACTION DETECTOR
DGPS	- DIFFERENTIAL GLOBAL POSITIONING SYSTEM
ENVI	- THE ENVIRONMENT FOR VISUALIZING IMAGES
FE	- FATOR DE ESCALA
FNEA	- FRACTAL NET EVOLUTION APPROACH
FOV	- FIELD OF VIEW
GDA94	- GEOCENTRIC DATUM OF AUSTRALIA - 1994
CHAID	- CHI-SQUARE AUTOMATIC INTERACTION DETECTOR
GLASOD	- GLOBAL ASSESSMENT OF SOIL DEGRADATION
GLCM	- GRAY LEVEL CO-OCCURRENCE MATRIX
GLDV	- GRAY LEVEL DIFFERENCE VECTOR
GNSS	- GLOBAL NAVIGATION SATELLITE SYSTEM
GPS	- GLOBAL POSITIONING SYSTEM
HRI	- HIGH RESOLUTION IMAGERY
ICBI	- ÍNDICE DE CONTRASTE BASEADO EM IMAGEM DE INTENSIDADE
IHRC	- INTERNATIONAL HURRICANE RESEARCH CENTER
IPT	- INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO
IRS	- INDIAN REMOTE SENSING
ISODATA	- ITERATIVE SELF-ORGANIZING DATA ANALYSIS
LASER	- LIGHT AMPLIFICATION BY STIMULATED EMISSION OF RADIATION
LABOGEF	- LABORATÓRIO DE GEOGRAFIA FÍSICA
LADAR	- LASER DETECTION AND RANGING
LASER	- LIGHT AMPLIFICATION BY STIMULATED EMISSION OF RADIATION
LIDAR	- LIGHT DETECTION AND RANGING
MGA94	- MAP GRID OF AUSTRALIA - 1994
MDS	- MODELO DIGITAL DE SUPERFÍCIE
MDSN	- MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO
MDT	- MODELO DIGITAL DE TERRENO
MMU	- MINIMAL MAPPING UNIT
NDVI	- NORMALIZED DIFFERENCE VEGETATION INDEX
NIR	- NEAR INFRARED
NN	- NEAREST NEIGHBOUR
OBIA	- OBJECT-BASED IMAGE ANALYSIS
PADAP	- PROGRAMA DE ASSENTAMENTO DIRIGIDO DO ALTO PARNAÍBA
PAN	- PANCROMÁTICA
PE	- PARÂMETRO DE ESCALA
PH	- PARÂMETRO DE HETEROGENEIDADE
PNUMA	- PROGRAMA DAS NAÇÕES UNIDAS PARA MEIO AMBIENTE
PRODECER	- PROGRAMA DE COOPERAÇÃO NIPO-BRASILEIRO PARA O DESENVOLVIMENTO DOS CERRADOS
QUEST	- QUICK-UNBIASED-EFFICIENT STATISTICAL TREE
RGB	- RED GREEN BLUE
RTK	- REAL TIME KINEMATIC
SIRGAS 2000	- SISTEMA DE REFERÊNCIA GEOCÊNTRICO PARA AS AMÉRICAS
SMPU	- SECRETARIA MUNICIPAL DE PLANEJAMENTO URBANO - UBERLÂNDIA
SPOT	- SATELLITE POUR L'OBSERVATION DE LA TERRE

SRTM	- SHUTTLE RADAR TOPOGRAPHY MISSION
TDIDT	- TOP-DOWN INDUCTION OF DECISION TREES
TIN	- TRIANGULATED IRREGULAR NETWORK
TLS	- TERRESTRIAL LASER SCANNING
UEPG	- UNIVERSIDADE ESTADUAL DE PONTA GROSSA
UFG	- UNIVERSIDADE FEDERAL DE GOIÁS
UFPR	- UNIVERSIDADE FEDERAL DO PARANÁ
UTM	- UNIVERSAL TRANSVERSE OF MERCATOR
WEKA	- WAIKATO ENVIRONMENT FOR KNOWLEDGE ANALYSIS

## SUMÁRIO

### RESUMO

### ABSTRACT

### LISTA DE ILUSTRAÇÕES

### LISTA DE SIGLAS E ABREVIATURAS

<b>1 INTRODUÇÃO .....</b>	<b>15</b>
1.1 CONSIDERAÇÕES INICIAIS.....	15
1.2 HIPÓTESE.....	17
1.3 OBJETIVOS.....	18
1.4 JUSTIFICATIVA E CONTRIBUIÇÃO CIENTÍFICA.....	19
1.5 ESTRUTURA DA TESE.....	19
<b>2 EMBASAMENTO TEÓRICO.....</b>	<b>21</b>
2.1 PROCESSOS EROSIVOS.....	21
2.1.1 Definição e tipos de erosão.....	21
2.1.2 Riscos associados aos processos erosivos.....	23
2.1.3 Fatores naturais que influenciam a erosão.....	24
2.1.4 Formação dos processos erosivos pluviais.....	26
2.1.5 Voçorocas.....	27
2.2 SISTEMA DE VARREDURA A LASER AEROTRANSPORTADO – ALS.....	31
<b>3 ESTADO DA ARTE.....</b>	<b>34</b>
3.1 MONITORAMENTO DE VOÇOROCAS.....	34
3.1.1 Monitoramento por mensurações no local.....	34
3.1.2 Monitoramento por sensoriamento remoto.....	35
3.1.3 Monitoramento com dados espectrais e altimétricos, processados por métodos semiautomáticos.....	36
3.2 CLASSIFICAÇÃO BASEADA EM RELAÇÕES DE HIERARQUIA E ÁRVORES DE DECISÃO.....	43
<b>4 MATERIAIS E MÉTODOS.....</b>	<b>47</b>
4.1 ÁREAS DE ESTUDO.....	47
4.1.1 Área de Estudo 1 – Uberlândia-MG.....	47
4.1.2 Área de Estudo 2 – Queensland – Austrália.....	52
4.2 MATERIAIS.....	54

4.3 METODOLOGIA.....	57
4.3.1 Processamento das nuvens de pontos ALS e geração de NDVI.....	58
4.3.2 Segmentação - geração de objetos-imagem.....	68
4.3.3 Planejamento da classificação.....	81
4.3.4 Classificação por árvores de decisão.....	90
4.3.5 Classificação de objetos por meio de lógica fuzzy e hierarquia.....	102
4.3.6 Avaliação da classificação.....	107
<b>5 RESULTADOS E DISCUSSÕES.....</b>	<b>111</b>
5.1 PROCESSAMENTO DA NUVEM DE PONTOS ALS DA ÁREA DE ESTUDO A1.....	111
5.2 PROCESSAMENTO DA NUVEM DE PONTOS ALS DA ÁREA DE ESTUDO A2.....	117
5.3 REGISTRO DOS DADOS ESPECTRAIS E ALTIMÉTRICOS DA ÁREA DE ESTUDO A1.....	123
5.4 GERAÇÃO DE OBJETOS.....	124
5.5 PLANEJAMENTO DA CLASSIFICAÇÃO.....	128
5.6 MINERAÇÃO DE DADOS.....	131
5.7 CLASSIFICAÇÃO DE OBJETOS POR MEIO DE LÓGICA FUZZY E HIERARQUIA.....	140
5.7.1 Definição da rede hierárquica.....	140
5.7.2 Seleção de atributos e regras de pertinência fuzzy.....	142
5.7.3 Classificação hierárquica.....	152
<b>6 CONCLUSÕES.....</b>	<b>162</b>
6.1 CONSIDERAÇÕES FINAIS.....	162
6.2 RECOMENDAÇÕES.....	165
<b>REFERÊNCIAS.....</b>	<b>167</b>
<b>DOCUMENTOS CONSULTADOS.....</b>	<b>177</b>
<b>APÊNDICE - REGISTRO DOS DADOS ESPECTRAIS E ALTIMÉTRICOS DA ÁREA DE ESTUDO A1.....</b>	<b>180</b>

## 1 INTRODUÇÃO

### 1.1 CONSIDERAÇÕES INICIAIS

O PNUMA (Programa das Nações Unidas para Meio Ambiente), por meio do projeto GLASOD (*Global Assessment of Human-induced Soil Degradation*), publicou, em 1990, o Mapa Mundial do Status de Indução Humana da Degradação dos Solos, segundo o qual se estima que a perda anual de solo agrícola no mundo, por erosão, seja da ordem de 6 a 7 milhões de hectares (OLDEMAN, HAKKELING e SOMBROEK, 1991; OLDEMAN e LYNDEN, 1996; GUERRA, 2005a).

Dentre os processos erosivos, as voçorocas representam os de maiores prejuízos ambientais, sociais e financeiros, devido à dispendiosa recuperação das áreas por elas degradadas.

A aplicação de medidas corretivas ou preventivas necessita da localização das voçorocas e monitoramento de sua evolução. A forma clássica de monitoramento é por estaqueamento, método amplamente utilizado, mas que leva à perda das estacas conforme o crescimento da voçoroca, além de permitir mensurar apenas a borda do barranco. O monitoramento por mensurações no local pode, ainda, ser realizado com equipamentos topográficos, receptores GNSS (*Global Navigation Satellite System*) ou Sistemas Terrestres de Varredura a LASER (TLS – *Terrestrial LASER<sup>1</sup> Scanning*). Com qualquer uma dessas técnicas, faz-se necessário o caminhamento nas bordas ou dentro da voçoroca, o que, além de perigoso, pode causar mais movimentos de massa, agravando a situação já instalada.

Alternativamente, o monitoramento pode ser feito remotamente com o uso de dados como fotos aéreas, imagens orbitais e dados altimétricos provenientes de Sistemas Aerotransportados de Varredura a LASER (ALS – *Airborne LASER Scanning*). A maioria dos estudos realizados neste escopo aponta o uso de técnicas

---

<sup>1</sup> LASER - *Light Amplification by Stimulated Emission of Radiation*

de fotointerpretação, geralmente em imagens de média resolução espacial (30m e 20m), com o delineamento das voçorocas por meio de digitalização das feições pelo intérprete. Os resultados são bastante subjetivos e pouco precisos devido à resolução espacial dos dados. Apesar de essas técnicas permitirem a localização das voçorocas, o monitoramento ao longo do tempo fica comprometido, em função de que as variações nas dimensões das feições costumam ser da ordem de centímetros a poucos metros, num curto período de tempo, o que não é perceptível em um pixel de 30 metros, por exemplo. Obviamente, o uso de imagens de alta resolução espacial, mesmo com a utilização das técnicas de fotointerpretação (procedimento bastante subjetivo e moroso), permite melhor monitoramento, mas apenas quando as alterações na configuração das feições sejam superiores ao tamanho do pixel.

Visando eliminar o subjetivismo no processo, métodos de classificação supervisionada ou não supervisionada podem ser aplicados. Entretanto, as imagens de alta resolução apresentam dificuldades à extração automática de informações porque se caracterizam pela grande heterogeneidade espacial e espectral para um mesmo objeto, o que dificulta o processo de classificação das mesmas, em abordagem orientada a pixel (WILKINSON, 2005).

As voçorocas possuem heterogeneidade espacial, espectral e altimétrica. Em termos espaciais, elas apresentam formato irregular, dimensões variadas, assimetria e relação largura/comprimento bastante variável, o que as diferencia das demais feições urbanas e rurais. Quanto às características espectrais, elas apresentam mistura de solos, vegetação e água. Elas são constituídas por elementos como cabeceira, canais e dígitos, que apresentam formas e tamanhos variados, o que sugere que o uso de abordagem orientada a objeto, usando técnicas de segmentação multirresolução, permita a classificação destes elementos em escalas diferentes. As voçorocas apresentam variação altimétrica de centímetros a metros, o que indica que a incorporação de dados altimétricos possa ser determinante na classificação das mesmas.

Em função dessas características particulares das voçorocas, o uso de métodos tradicionais de classificação, orientados ao pixel e usando apenas informações espectrais, é inviável para a delimitação das voçorocas, já que as mesmas não constituem uma classe de uso do solo, e sim um objeto específico.

O uso de dados provenientes de fontes diversas pode auxiliar na discriminação das feições. Entretanto, o grande volume de dados resultante necessita de técnicas de classificação que permitam o estabelecimento de regras para discriminação dos objetos, selecionando os tipos de dados, atributos e valores limiares mais adequados a este propósito. Algoritmos de indução de árvores de decisão auxiliam na seleção dessas informações e no estabelecimento de regras para discriminação dos objetos de interesse.

Neste estudo, propôs-se o uso de dados espectrais, oriundos de aerofotos ou imagens orbitais, de alta resolução espacial, associados a dados altimétricos provenientes de ALS, processados com abordagem orientada a objeto (objetos gerados por segmentação multirresolução), para delimitação de voçorocas. A seleção dos dados de entrada mais relevantes e dos atributos discriminantes da classe voçoroca foi realizada empiricamente, com base no conhecimento especialista, e com auxílio de algoritmos de indução de árvores de decisão. Os objetos provenientes da segmentação foram classificados pelo algoritmo de árvores de decisão, que permitiu o delineamento de regras de decisão, e por classificação hierárquica.

## 1.2 HIPÓTESE

A hipótese considerada neste trabalho é:

É possível delimitar as feições de voçoroca em um procedimento semiautomático de classificação, usando aerofotos ou imagens de satélite de alta resolução espacial, com a incorporação de dados altimétricos e de atributos não espectrais, como textura, usando-se abordagem orientada a objeto, árvores de

decisão e classificação hierárquica.

### 1.3 OBJETIVOS

Objetivo geral: propor uma metodologia para delimitação de voçorocas, em função de dados de sensoriamento remoto, selecionando atributos que possam auxiliar no estabelecimento de uma base de regras de decisão que permita a identificação destas feições.

Tem-se por objetivos específicos:

- a) Determinar os parâmetros ótimos para a segmentação, que permitam delinear os objetos constituintes do sistema voçoroca, como cabeceira, canais e dígitos;
- b) Selecionar, por análise visual, um conjunto de descritores que permitam a discriminação das feições do tipo voçoroca dentre as demais na cena;
- c) Usando algoritmo de indução de árvore de decisão, encontrar os descritores mais relevantes à classificação da voçoroca e obter uma base de regras que explicita o conhecimento, para a classificação;
- d) Realizar a classificação por meio de árvore de decisão, de forma a verificar a possibilidade da identificação da classe voçoroca, de forma automática;
- e) Realizar a classificação semiautomática, por classificação hierárquica, adequando, conforme conhecimento especialista, os descritores e a base de regras, apontados pela árvore de decisão;
- f) Avaliar a qualidade temática das classificações obtidas, por meio de matrizes de confusão e de análise visual – qualitativa, e
- g) Comparar os resultados obtidos por classificação por árvore de decisão e por classificação hierárquica.



## 1.4 JUSTIFICATIVA E CONTRIBUIÇÃO CIENTÍFICA

As perdas de solo ocasionadas por processos erosivos geram danos ambientais tanto às áreas urbanas quanto às áreas rurais, além dos prejuízos financeiros. Em se tratando de áreas rurais (foco deste estudo), as voçorocas ocupam lugar anteriormente destinado ao plantio ou à criação de animais, provocam assoreamento dos rios a jusante e, quando atingem o lençol freático, causam danos aos recursos hídricos da região (contaminação).

A identificação e o mapeamento dessas feições são imprescindíveis para o monitoramento dos processos erosivos e planejamento de medidas mitigatórias. Técnicas de extração automática, com caráter não subjetivo e que permitam o processamento dos dados com maior agilidade, trarão benefícios ao planejamento ambiental para o monitoramento dessas áreas degradadas.

Estudos realizados anteriormente, aplicando classificação por árvores de decisão e aliando dados espectrais e altimétricos, na investigação de questões relacionadas ao mapeamento urbano, têm apresentado resultados promissores. Contudo, escassos estudos têm sido realizados no que concerne ao uso combinado de dados espectrais e altimétricos, tampouco com algoritmos de árvores de decisão, na investigação de processos erosivos. Em adição, existe a necessidade de mais investigações sobre aplicações multidisciplinares das técnicas de análise orientada a objeto (*Object-Based Image Analysis – OBIA*).

Vale ressaltar que o uso conjugado de dados de sensoriamento remoto, provenientes de diferentes fontes, é ainda um tema aberto à comunidade científica, bem como a análise de parâmetros descritores de feições.

## 1.5 ESTRUTURA DA TESE

As considerações iniciais sobre o estudo realizado, bem como hipótese, objetivos, justificativa e contribuição científica, estão explicitados no capítulo 1. No

capítulo 2 apresenta-se o embasamento teórico. No capítulo 3 expõe-se o estado de arte relativo ao mapeamento de voçorocas e à classificação baseada em relações de hierarquia e árvores de decisão. No capítulo 4 são apresentados os materiais e métodos empregados para elaboração do estudo. No capítulo 5 os resultados são apresentados e discutidos. No capítulo 6 são apontadas as considerações finais e recomendações.

## 2 EMBASAMENTO TEÓRICO

Neste capítulo serão apresentados alguns aspectos definidores sobre processos erosivos, principalmente no que tange à formação de voçorocas, e sobre o sistema de varredura a LASER aerotransportado, que constituiu uma das fontes de dados para realização deste estudo.

### 2.1 PROCESSOS EROSIVOS

Esta seção apresenta noções sobre os processos erosivos, dando-se ênfase às características do objeto de investigação deste estudo, as voçorocas.

#### 2.1.1 Definição e tipos de erosão

Erosão é o processo de desgaste da superfície do terreno, ocasionado pela desagregação e remoção de partículas do solo ou de fragmentos e partículas de rochas e pela ação combinada da gravidade com a água, vento, gelo e/ou organismos (plantas e animais) (INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO (1986) apud SALOMÃO, 2005; BIGARELLA, 2007). O processo ocorre em duas fases: a primeira pela remoção das partículas (por fragmentação mecânica ou decomposição química das rochas), a segunda pelo seu subsequente transporte. Quando não há mais energia para continuar ocorrendo o transporte, surge uma terceira fase, que é a da deposição do material transportado (GUERRA, 1994).

Uma erosão dita normal é aquela que reflete certo equilíbrio na natureza, quando diversos processos atuam de forma contraditória, formando e erodindo os solos. Quando o equilíbrio é rompido e ocorre uma intensificação da erosão, denominada erosão acelerada, os processos de formação dos solos são mais velozes e não permitem que esses se regenerem. A erosão acelerada, quando

provocada por atividades humanas, é denominada erosão antrópica (DAEE/IPT, 1989).

O desequilíbrio causa a degradação dos solos que é, atualmente, um dos problemas ambientais mais importantes, afetando as terras agrícolas, urbanas e com vegetação natural. Nas áreas rurais, a degradação dos solos está intimamente relacionada com o avanço da agricultura, devido à falta de práticas de conservação dos solos. Os solos erodem não apenas porque chove forte, mas porque eles foram desmatados e cultivados de maneira incorreta, o que acelera os processos erosivos (GUERRA, 2005b).

Entre os tipos de erosão estão os causados pela gravidade, pelo vento (eólica) e pela água - hídrica (fluvial, pluvial, glacial, ondas e correntes marinhas) (MORGAN, 2005). A figura 1 ilustra os tipos de erosão por gravidade, eólica e hídrica (objeto de estudo desta pesquisa).




FIGURA 1 - TIPOS DE EROSÃO

FONTE: A e B – DOMÍNIO PÚBLICO; C) LABOGEF – UFG (2012)

Os processos erosivos ocasionados pelas águas das chuvas ocorrem em quase toda a superfície terrestre, principalmente nas áreas com clima tropical, onde os totais pluviométricos são mais elevados do que em outras regiões. Em muitas dessas áreas, como é o caso do Brasil, há ainda o agravante de que as chuvas concentram-se em certas estações do ano. Além disso, no Brasil há uma combinação dos fatores intensificadores dos processos erosivos: altos índices pluviométricos, fragilidade dos solos e os efeitos do rápido desenvolvimento econômico.

### 2.1.2 Riscos associados aos processos erosivos

Os solos desenvolvem uma série de funções-chave: produção de alimento, acúmulo de matéria orgânica, água e nutrientes, provisão de habitat para uma vasta variedade de organismos e preservação do registro de atividades humanas (arqueologia). Qualquer degradação do solo pode impactar a habilidade do mesmo de desempenhar essas funções. No que tange à agricultura, os efeitos locais da erosão resultam na redução da profundidade do solo cultivável e no declínio da fertilidade do solo (necessidade de aumento do uso de fertilizantes), ocasionando perda de produtividade e posterior abandono da terra, com consequências para a produção de alimentos e segurança alimentar e um declínio substancial do valor da terra. Outros efeitos a serem considerados são a redução de carbono, o movimento de nitrogênio e a remoção de fósforo. Solos erodidos podem perder de 75% a 80% do seu conteúdo de carbono, com consequente emissão de carbono para a atmosfera. A erosão é, por isso, um contribuinte para a alteração do clima, pois aumentando o conteúdo de dióxido de carbono na atmosfera, aumenta o efeito estufa. Outros danos ambientais são causados pela sedimentação. Essa pode ocasionar inundação, devido à redução da capacidade dos rios e bacias de drenagem. Além disso, a vida útil de reservatórios pode ser encurtada, bem como os canais de irrigação podem ser bloqueados. Corpos d'água podem ser poluídos devido à presença de produtos químicos absorvidos pelos sedimentos, podendo aumentar os níveis de nitrogênio e fósforo, resultando em eutrofização. O controle de erosão tem potencial para sequestrar carbono bem como para restaurar solos degradados e melhorar a qualidade da água (MORGAN, 2005).

### 2.1.3 Fatores naturais que influenciam a erosão

Clima e fatores litológicos, hidrográficos, topográficos e biogeográficos fazem parte de um quadro natural que, no conjunto, formam uma cadeia, na qual

cada elemento deve estar em equilíbrio com os demais. É do comportamento desses fatores naturais que depende a intensidade de atuação de cada processo morfogenético<sup>2</sup>, havendo, conseqüentemente, maior ou menor ação erosiva (VIEIRA, 1978). Apesar de a erosão do solo ser um processo físico com variação global considerável em sua severidade e frequência, onde e quando a erosão ocorre são aspectos fortemente influenciados, também, por fatores sociais, econômicos, políticos e institucionais (MORGAN, 2005).

Os fatores naturais podem ser divididos em extrínsecos e intrínsecos. Entre os fatores intrínsecos estão: a cobertura vegetal, o relevo, o clima e o substrato geológico.

Quanto ao clima, em se tratando de erosão hídrica, o fator mais importante é a precipitação. Devem-se considerar o volume de precipitação, duração, intensidade e frequência, condicionados à distribuição cronológica ao longo das estações do ano. Além da precipitação, devem ser considerados as variações de temperatura, atuação das massas de ar e o balanço hídrico (VIEIRA, 1978).

Quanto aos processos litológicos, eles estão relacionados com a estrutura geológica das rochas e são resultantes da maior ou menor resistência dos corpos rochosos aos processos erosivos. As transformações sofridas pelas rochas resultarão em diferentes tipos de solo. O tipo de solo é o fator intrínseco principal da erosão, pois o solo, além de comandar a erosão, é afetado por ela. Erosão e solo são indissociáveis (DAEE/IPT, 1989). O tipo de solo indica a susceptibilidade do solo à erosão, ou seja, sua erodibilidade. Fatores como textura, teor e estabilidade dos agregados, estrutura, porosidade, composição, teor de acidez do solo, teor de matéria orgânica, densidade aparente, espessura, relação textural entre os horizontes ou camadas, influenciam na erodibilidade.

Outro fator, determinante na formação de voçorocas, e altamente dependente do tipo de solo, é a presença e a profundidade do lençol freático

---

<sup>2</sup> Processos morfogenéticos são os responsáveis pela esculturação das formas de relevo, representando a ação da dinâmica externa sobre as vertentes. Podem-se citar o intemperismo, movimentos do regolito, processo pluvial e a ação biológica (CHRISTOFOLETTI, 1980, p. 27-31).

(DAEE/IPT, 1989; GUERRA, 1994). Silva (2005) discorre sobre a análise morfológica dos solos e suas relações com os processos de erosão. Guerra e Botelho (2001) apresentam as principais classes de solos e sua suscetibilidade à erosão, destacando as áreas, no Brasil, que são críticas quanto à incidência de processos erosivos, inclusive a região do Triângulo Mineiro (localização de uma das áreas de estudo selecionadas para o desenvolvimento deste trabalho).

Entre os fatores hidrográficos, devem ser analisadas a bacia hidrográfica e a rede de drenagem. Quanto aos fatores topográficos, o relevo exerce papel fundamental nos estudos erosivos, sendo a declividade o fator mais importante, pois quanto maior a inclinação da vertente, maior a quantidade de água que escoar superficialmente, acelerando os processos erosivos. O grau, a forma e a extensão do declive devem também ser considerados (VIEIRA, 1978; DAEE/IPT, 1989).

Entre os fatores biogeográficos estão: a presença ou ausência da vegetação, a atuação dos animais e a ação do homem na utilização da terra. A vegetação, seja natural ou de cultura agrícola, atua como fator controlador do escoamento superficial, protegendo o solo contra o impacto das gotas da chuva, dispersando e interceptando as gotas de água antes que elas atinjam o solo, formando poros e canais que aumentam a infiltração da água pela ação das raízes das plantas, aumentando a capacidade do solo de reter água pela ação da matéria orgânica, diminuindo o escoamento superficial, entre outros. Além disso, as plantas isolam termicamente o solo, evitando que haja grande variação de temperatura, reduzindo seu ressecamento (TOMINAGA, SANTORO e AMARAL, 2009).

O pisoteio dos animais influencia a dinâmica dos processos morfogenéticos. As formigas, principalmente as saúvas, escavam o solo, às vezes profundamente, onde a água poderá agir facilmente, além de dificultarem e impedirem o crescimento e o desenvolvimento da vegetação. Outros animais, como os tatus, atuam destruindo o solo e ativando os processos erosivos (VIEIRA, 1978).

#### 2.1.4 Formação dos processos erosivos pluviais

A erosão pluvial está relacionada com os vários caminhos tomados pela água da chuva na sua passagem através da cobertura vegetal e com o seu movimento na superfície do solo. O processo erosivo inicia quando as gotas de chuva começam a bater no solo, iniciando o efeito denominado splash (erosão por salpicamento), que pode causar a ruptura de agregados, formando crostas até a selagem do topo do solo, dificultando a infiltração de água, gerando a formação de poças (*ponds*) à medida que o solo torna-se saturado. A partir daí, a água começa a escoar na superfície, primeiramente em lençol, depois através de fluxos lineares que evoluem para microrravinas, podendo, algumas, formar cabeceiras e, algumas dessas cabeceiras, podem bifurcar formando novas ravinas. Finalmente, as ravinas podem evoluir e se conectar com processos erosivos de maiores proporções, que são as voçorocas. A formação dos processos erosivos pluviais manifesta-se na seguinte sequência, ilustrada pela figura 2 (GUERRA, 2005):

splash → ruptura dos agregados → formação de crostas → selagem → diminuição da infiltração → formação de poças → escoamento superficial → microrravinas → ravinas → voçorocas

Os diferentes processos erosivos variam no tempo e no espaço. As variações podem ocorrer em períodos que podem ser de poucas horas (como durante um evento chuvoso), como podem ser sazonais ao longo do ano, ou em longo prazo, refletindo os efeitos da ocupação humana, ou de anos mais secos e mais úmidos. Quanto à variação espacial, as modificações nos processos erosivos podem ocorrer em termos de magnitude (GUERRA, 1994).



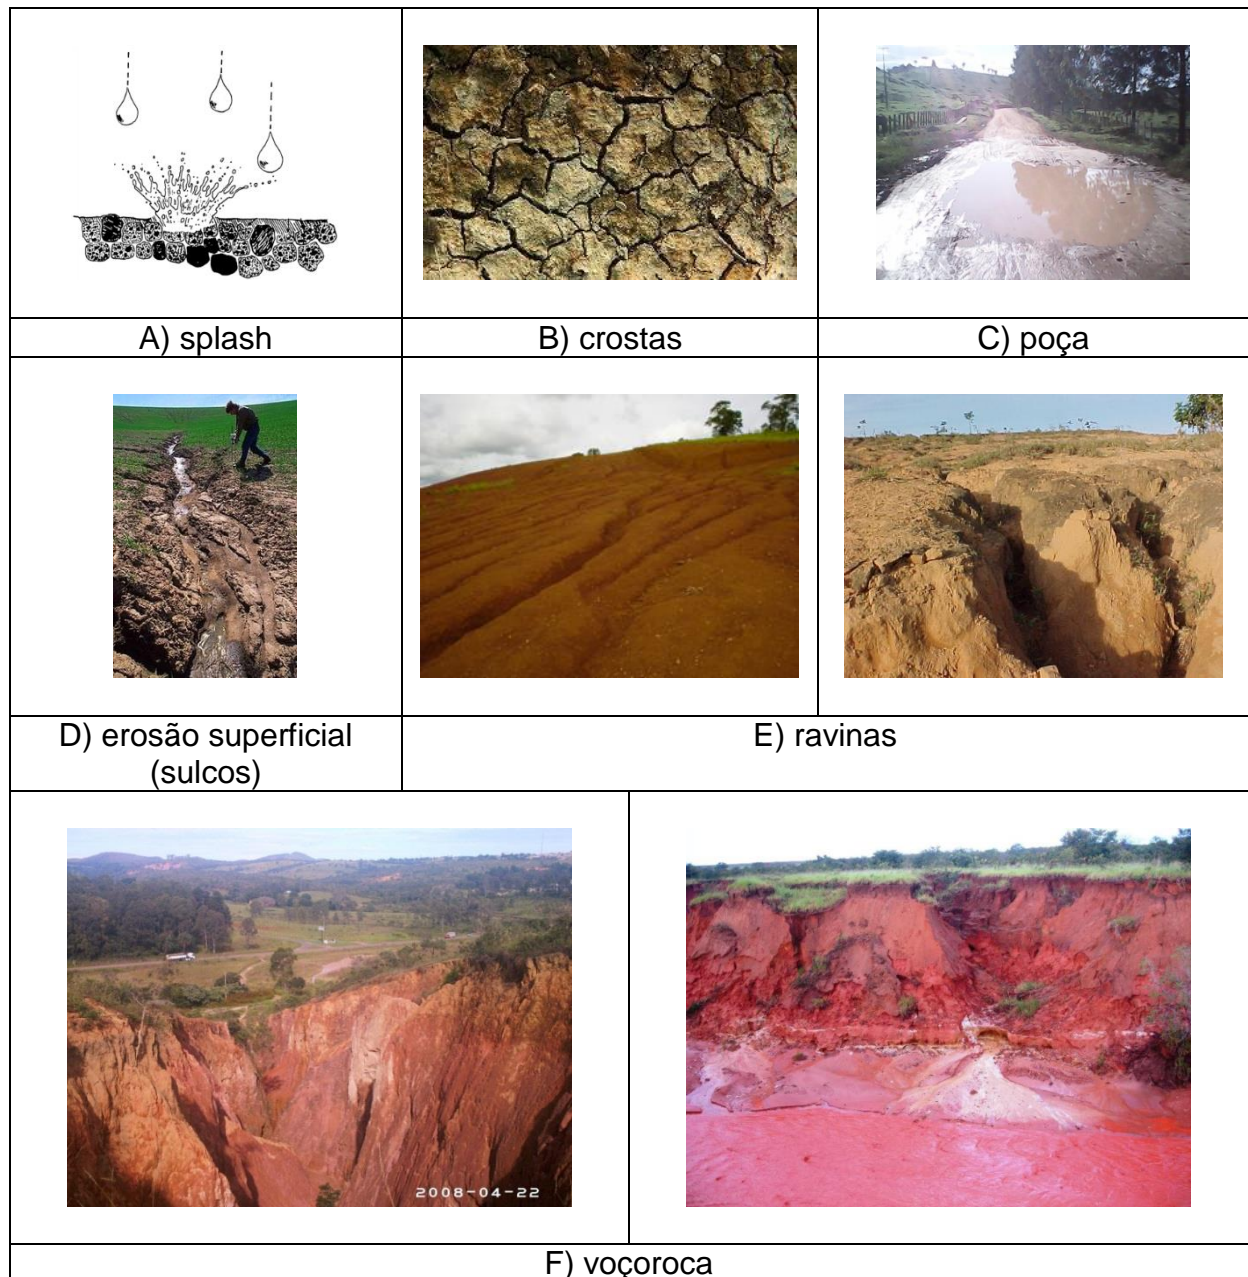


FIGURA 2 – FORMAÇÃO DOS PROCESSOS EROSIVOS DE ORIGEM HÍDRICA  
 FONTE: A) ADAPTADO DE DAEE/IPT (1989); B) BARBERA (2012); C) NASCIMENTO (2015); D) DYKINGA (2015); E) CPRM (2015), CASTRO (2004); F) QUEIROZ (2015); CASTRO (2004)

### 2.1.5 Voçorocas

As ravinas são “sulcos produzidos nos terrenos devido ao trabalho erosivo das águas de escoamento” (GUERRA e GUERRA, 1997, p. 512). Acabam por originar as voçorocas que podem ser definidas como:

“Voçoroca: Escavação ou rasgão do solo ou de rocha decomposta, ocasionada pela erosão do lençol de escoamento superficial... As voçorocas, quando em grande número e relativamente paralelas, dão aparecimento a verdadeiras áreas de badland, ou ainda área voçorocada. As voçorocas podem também ser formadas pelo escoamento subsuperficial.” (GUERRA e GUERRA, 1997, p. 637)

Uma definição mais abrangente explicita como:

“As boçorocas são depressões profundas, circundadas por vertentes quase verticais, que se alargam nas proximidades das cabeceiras devido à intensa atividade erosiva regressiva e se afunilam junto à foz do curso d’água que a percorre, cortando sedimentos arenosos de fraca coesão, sem apresentar forte declive longitudinal.” VIEIRA (1978, p.7)

As ravinas são canais contínuos, estreitos e de pouca profundidade, que podem ser suprimidos por máquinas agrícolas, ao contrário das voçorocas que, geralmente, são feições permanentes. Quando ocorre o alargamento das ravinas, causado pelo escoamento superficial e subsuperficial, originam-se as voçorocas, que ocorrem tanto em áreas rurais quanto em áreas urbanas, inviabilizando o uso do solo (GUERRA, 1994).

Etimologicamente, voçoroca é proveniente do tupi guarani: ibi ou yby (terra) e çoroc (rasgão), sofrendo alteração para ubu-çoroc que significa terra rasgada ou fendida, rasgão de solo. Outra origem do termo, proveniente do tupi, mbaê-çorogca ou mvoçoroca, pode ser traduzido como coisa rasgada ou rasgadura (VIEIRA, 1978). No Brasil, é correto usar os termos voçoroca e boçoroca. Neste trabalho, optou-se por usar o termo voçoroca, por ser mais usual na literatura nacional.

Existem no Brasil dois critérios para distinção entre ravinas e voçorocas, um relacionado ao caráter dimensional (quantitativo) e outro ao atingimento do lençol freático (qualitativo). Segundo o critério dimensional, as ravinas são incisões de até 0,5m de profundidade e largura, sendo consideradas voçorocas as incisões com dimensões superiores a essas, podendo atingir dezenas de metros de largura e profundidade, até centenas de metros de comprimento (OLIVEIRA, 2005). Este

critério é o predominante na literatura nacional e internacional e será o adotado neste trabalho.

Segundo o outro critério, difundido pelos técnicos do Instituto de Pesquisas Tecnológicas do Estado de São Paulo (IPT, 1986), as ravinas são canais criados pela ação do escoamento superficial, enquanto que as voçorocas são canais esculpidos pelo afloramento do lençol freático. Esta definição é útil, tecnicamente, por facilitar o planejamento de obras de controle e recuperação, entretanto, dificulta a compreensão da evolução do processo erosivo a partir dos sulcos que evoluem para ravinas e daí para voçorocas (OLIVEIRA, 2005).

Guerra (1994) caracteriza as voçorocas como sendo processos erosivos relativamente permanentes nas encostas, possuindo paredes laterais íngremes e, em geral, fundo chato, ocorrendo fluxo de água no seu interior durante os eventos chuvosos. Quando se aprofundam, podem atingir o lençol freático. Em comparação com os canais fluviais, as voçorocas possuem, geralmente, maior profundidade e menor largura, estando associadas a processos de erosão acelerada e, conseqüentemente, com a instabilidade da paisagem. A figura 3 ilustra duas voçorocas de grandes proporções, uma em ambiente agrícola e a outra em ambiente urbanizado.

Em uma voçoroca atuam processos de erosão superficial e interna, solapamentos e descalçamentos, desabamentos e escorregamentos, que se conjugam dotando a voçoroca de elevado poder destrutivo. Isto pode ser verificado nas grandes dimensões, grandes velocidades de avanço e rápida evolução de seus ramos ativos, tornando sua contenção mais difícil. Quando a voçoroca atinge, em profundidade, o lençol freático ou nível d'água de subsuperfície, pode ocorrer o aparecimento de surgências d'água (minação de água no fundo da voçoroca). Se este fluxo d'água do fundo e das paredes da voçoroca tiver continuidade para o interior do terreno, haverá carreamento do material em profundidade, formando vazios no interior do solo. Essa erosão interna, denominada *pipping*, avança para o interior do solo na forma de tubos, processo esse conhecido como entubamento.

Caso esses vazios tornem-se significativos, podem originar colapsos de terreno, com desabamentos que alargam a voçoroca ou criam novos ramos (DAEE/IPT, 1989).



FIGURA 3 – VOÇOROCAS DE GRANDES DIMENSÕES  
 FONTE: A) CASTRO (2004); B) IPT (2015)

As voçorocas representam uma das formas mais destrutivas de erosão, ocasionando a degradação dos solos, solapamento de obras de infraestrutura, perda de áreas agricultáveis, alteração dos corredores de transporte do fluxo d'água e rebaixamento dos níveis de reservatórios (VALENTIN, POESEN e YONG, 2005). A degradação compromete a fertilidade natural do solo também em áreas afastadas de onde a erosão está ocorrendo, gerando impactos nos recursos hídricos como rios, baías e reservatórios, que ficam assoreados e/ou poluídos (COSTA e BACELLAR, 2007).

## 2.2 SISTEMA DE VARREDURA A LASER AEROTRANSPORTADO - ALS

O ALS, também denominado como LIDAR (*Light Detection And Ranging*) ou LADAR (*LASER Detection And Ranging*) é um sensor remoto ativo. O próprio sistema emite energia em direção ao objeto para depois medir a parcela refletida desta energia.

A aquisição de dados é feita com o equipamento ALS a bordo de uma aeronave, sobrevoando uma determinada região. O equipamento realiza uma varredura no chão em direção perpendicular à direção do voo, registrando o tempo de ida e retorno do pulso emitido, o qual se desloca na velocidade da luz.

A maioria dos sistemas ALS usados para mapeamento topográfico utilizam a luz LASER no infravermelho próximo, na região de 1040 a 1060nm. A reflexão do sinal pode também ser armazenada e usada para a geração da imagem de intensidade. A área de cobertura de cada pulso é aproximadamente circular e varia com o ângulo de varredura e a topografia do terreno. Apesar de a luz do LASER possuir baixa divergência, o que torna seu percurso similar à concepção geométrica da linha reta, essa divergência existe e é, tipicamente, de 1 mrad. Como consequência da divergência do pulso, cada pulso LASER transmitido pode resultar em múltiplos retornos. O registro da primeira e da última reflexão de cada pulso, por exemplo, pode permitir a detecção de alturas de árvores, linhas de transmissão, construções, entre outros. O pós-processamento dos dados originais irá resultar em diversos arquivos de ALS, que se referem a: primeiro retorno, possíveis retornos intermediários, último retorno e intensidade (que facilita a identificação dos objetos nas imagens) (ACKERMANN, 1999; AXELSSON, 1999 e 2000; BALTSAVIAS, 1999).

O resultado dos registros e do pós-processamento dos dados obtidos pela varredura é uma massa de pontos irregularmente distribuídos, denominado *mass*

*points*. A irregularidade da distribuição está relacionada com o espelho de varredura do sensor, e o espaçamento dos pontos está relacionado com a densidade de amostragem que varia normalmente de 1 ponto por 20 m<sup>2</sup> a 20 pontos por m<sup>2</sup> para uma altura de voo de 1000m (JENSEN, 2009). A densidade depende principalmente da altura de voo. Os pontos podem ser usados diretamente para a construção de modelos digitais de superfície, ou podem ser filtrados e interpolados para obtenção de uma rede regular de pontos.

A maioria dos sistemas ALS fornece um arquivo de intensidade junto com os dados de múltiplos retornos. Em muitos casos, a intensidade registrada não é a integração dos ecos que retornaram de todos os pulsos, mas apenas os seus máximos. Vale salientar que, apesar de o feixe LASER estar na faixa do infravermelho próximo, uma imagem de intensidade LIDAR não apresentará a reflectância dos objetos da mesma forma que uma imagem multiespectral na região do infravermelho próximo. Deve-se levar em conta que o feixe LASER é monocromático e tem uma largura de banda extremamente pequena (por exemplo, de 2 a 5 nm), normalmente centrada em um comprimento de onda do infravermelho próximo (por exemplo, 1064 nm). Em comparação, as imagens multiespectrais possuem bandas com larguras de 50 a 100 nm (JENSEN, 2009).

A figura 4a ilustra um recorte da imagem de intensidade e a figura 4b da banda do infravermelho próximo (NIR – *Near InfraRed*) do sensor Ikonos. Pode-se perceber que as duas imagens são diferentes, por exemplo, na região de vegetação arbórea, assinalada com um círculo amarelo. A vegetação, que possui alta reflectância nesta faixa do espectro eletromagnético, aparece mais clara na imagem Ikonos e mais escura na imagem de intensidade. Uma explicação para este fato seria que quando os pulsos emitidos pelo ALS encontram árvores eles passam por múltiplas camadas de folhas dentro do dossel, o que reduz a quantidade de energia retroespalhada em direção ao receptor. Por isso as árvores aparecem escuras na imagem de intensidade. As áreas de gramado e/ou vegetação rasteira aparecem mais claras que as árvores na imagem de intensidade, pois os pulsos ALS não são



absorvidos ou espalhados na direção oposta ao ALS. Ao contrário, um forte retorno ocorre nessas superfícies, que misturam áreas gramadas e de solo exposto, tornando-as brilhantes nas imagens de intensidade. Outros fatores que podem explicar essa diferença nos dois tipos de imagem são: a distância ao alvo, o ângulo de incidência e a dispersão atmosférica (JENSEN, 2009).




FIGURA 4 – IMAGEM DE INTENSIDADE ALS (a) E DA BANDA NIR – IKONOS (b)  
FONTE: A AUTORA (2015)

O arquivo que contém os dados da varredura apresenta, para cada ponto medido, as coordenadas planimétricas, as altitudes referentes a cada um dos retornos armazenados (primeiro, último e intermediário) e a intensidade do retorno. O formato do arquivo é o LAS (LASer), que é um formato binário, público, para troca de dados de nuvens de pontos tridimensionais entre os fornecedores e os usuários desse tipo de dados. O arquivo LAS contém as informações dos múltiplos retornos. Outro formato de arquivo comum para este tipo de dados é o ASCII, que apresenta as coordenadas planimétricas (XY), as informações de altura referentes a um único retorno (Z) e a intensidade (I).

### **3 ESTADO DA ARTE**

#### **3.1 MONITORAMENTO DE VOÇOROCAS**

##### **3.1.1 Monitoramento por mensurações no local**

O estudo dos processos erosivos vem sendo feito há diversas décadas, em todo o mundo, usando diferentes métodos e técnicas, dependendo dos objetivos do estudo, dos recursos humanos e financeiros disponíveis, das condições climáticas, dos tipos de solo, das condições ambientais e de outras características relevantes para o tema em questão. O monitoramento refere-se às mensurações sistemáticas de um processo erosivo, sendo necessária a coletas de dados, em intervalos que podem ser fixos ou não, dependendo do que está sendo estudado (GUERRA, 2005).

O mapeamento e monitoramento de áreas atingidas por voçorocas, comumente, é realizado a partir de medidas efetuadas no local, com a técnica de estaqueamento (figura 5), sendo considerada a técnica mais utilizada no Brasil e no mundo, em função de ser barata, simples e de fácil execução (HESSEL e VAN ASCH, 2003; GUERRA, 2005; MORGAN, 2005). As principais vantagens do estaqueamento são o baixo custo na instauração da técnica e poucos impactos no terreno investigado. Como principal desvantagem está o fato de que a técnica só permite a quantificação do recuo da borda do barranco (FRANCISCO e NUNES, 2009).






FIGURA 5 – ESTAQUEAMENTO PARA MONITORAMENTO DE VOÇOROCA  
FONTE: GUERRA (2005)

Levantamentos topográficos convencionais ou com rastreamento de satélites GNSS também podem ser aplicados para mapeamento e monitoramento das voçorocas (LEAL e RODRIGUES, 2011). Esses métodos, além de espacialmente limitados, consomem tempo e trabalho intensivo. Alternativamente, podem-se utilizar sistemas de varredura a LASER terrestre (PERROY *et al.*, 2010; RAMOS *et al.*, 2011). Entretanto, apesar de as mensurações serem realizadas de forma remota, fornecendo maior amostragem de pontos, rapidez e precisão, ainda há a necessidade de deslocamento até a área de estudo e de instalação do equipamento em várias posições para o levantamento total das feições, implicando em movimentação sobre as feições erosivas e dispêndio de tempo para coleta dos dados. A movimentação sobre as feições erosivas pode agravar a situação já instalada e provocar riscos aos condutores do levantamento.

### 3.1.2 Monitoramento por sensoriamento remoto

A fim de evitar levantamentos no local, técnicas aerofotogramétricas vêm sendo usadas para fotointerpretação e geração de Modelo Digital de Terreno (MDT), com a finalidade de mapear voçorocas (BETTS e DEROSE, 1999; FADUL *et al.*, 1999; FLUGEL *et al.*, 2003; MARTÍNEZ-CASASNOVAS, 2003; POESEN *et al.*, 2003;

MARTÍNEZ-CASASNOVAS, RAMOS e POESEN, 2004). Um aspecto a ser considerado é a escala das aerofotos que, se for pequena, fornecerá MDTs de baixa resolução e, conseqüentemente, somente voçorocas de dimensões compatíveis com a escala usada poderão ser mapeadas. A recomendação é de que sejam usadas aerofotos em escalas maiores que 1:10.000 (DABA, RIEGER e STRAUSS, 2003). Estudos mais recentes, usando aerofotos digitais e de alta resolução, têm permitido estudos mais detalhados sobre as voçorocas (MARZOLFF e POESEN, 2009).

As imagens de satélite têm sido analisadas para a identificação de áreas com risco de erosão (KING *et al.*, 2005; VRIELING, RODRIGUES e STERK, 2005; VRIELING, 2007), para identificação do grau de atividade das voçorocas em função da cobertura vegetal (MARTÍNEZ-CASASNOVAS e ZARAGOZA, 1996), para predição de perda de solo e das áreas susceptíveis à erosão por voçorocamento (LE ROUX, 2011) e para classificação de voçorocas a partir de imagens de média resolução espacial (KNIGHT *et al.*, 2007; TARUVINGA, 2008). Estudos realizados com base em imagens de média resolução espacial, como Landsat, CBERS (China-Brazil *Earth Resources Satellite*), SPOT (*Satellite Pour l'Observation de la Terre*), ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*), bem como em dados altimétricos provenientes do SRTM (*Shuttle Radar Topography Mission*), têm aplicação limitada à localização das voçorocas, não permitindo seu monitoramento, em função da baixa resolução espacial dos dados. Estudos com base em imagens de alta resolução espacial, como as provenientes dos sensores Ikonos, QuickBird, WorldView, RapidEye, GeoEye, permitem não apenas a localização, mas também a delimitação das voçorocas (SANTOS e FARIA, 2011).

### 3.1.3 Monitoramento com dados espectrais e altimétricos, processados por métodos semiautomáticos

Além dos dados espectrais, dados altimétricos provenientes de ALS têm sido usados visando a geração de MDTs para o cálculo volumétrico e estimativas de

perda de solo em voçorocas. Estudos com processamento de dados multifonte mostram uma busca por métodos automáticos ou semiautomáticos, em abordagem orientada a objeto, para detecção, mapeamento e monitoramento, bem como para cálculos volumétricos e modelos preditivos de risco de erosão.

James, Watson e Hansen (2007) realizaram estudo para uma área localizada na Carolina do Sul, para duas voçorocas sob densa cobertura florestal. O estudo avaliou a acurácia dos mapas gerados a partir de dados ALS quando comparados a observações topográficas realizadas em campo. Os dados derivados de ALS permitiram a identificação e caracterização da localização, extensão e densidade de canais das duas voçorocas. Os mapas permitiram a identificação de voçorocas com menos de 3 metros de largura no topo, mesmo sob cobertura florestal. Comparando com as seções transversais levantadas em campo, as seções obtidas a partir do ALS apresentaram-se muito largas e rasas, com paredes laterais menos acentuadas. Isso pode ser resultado da filtragem dos dados ALS ou do sombreamento dos feixes do ALS devido às voçorocas profundamente enraizadas.

Eustace, Pringle e Witte (2009) utilizaram dados ALS (com espaçamento entre os pontos de 0,30 m) para detectar e mapear a extensão e volume de voçorocas, para uma área de estudo na represa Fitzroy, localizada no lago Great Barrier Reef, na costa leste da Austrália. As nuvens de pontos provenientes do ALS foram usadas na geração do MDT e da imagem de intensidade, ambos com resolução espacial de 0,5m. Após a segmentação multirresolução, os objetos foram classificados como “voçoroca” ou “não voçoroca”. Como dados de entrada foram usados: a imagem de intensidade, declividade do MDT, desvio-padrão da declividade e textura do MDT. Combinações de atributos dos objetos-imagem (declividade, textura, desvio-padrão da declividade, comprimento do lado mais longo do objeto, proporção comprimento/largura, ajuste retangular, assimetria e relação com vizinhos) foram testadas para determinar os melhores limiares e os atributos que mais acuradamente classificariam as voçorocas. A segmentação ótima foi obtida com um fator de escala (FE) = 50, o qual forneceu bordas de voçorocas bem

definidas. Usando-se o  $FE = 200$  as voçorocas não foram delineadas com detalhe suficiente e com  $FE = 20$  as voçorocas foram segmentadas excessivamente. Testes iniciais, que usaram a declividade como regra exclusiva para a classificação de voçorocas, demonstraram que muitas áreas com rampas de colinas longas foram alocadas incorretamente à classe voçoroca. Regras baseadas em textura foram capazes de incluir na classe voçoroca os objetos cujos pixels constituintes eram relativamente heterogêneos. Muitos objetos da classe voçoroca eram altamente variáveis em relação à declividade e topografia (MDT), o que leva a valores grandes de textura e uma melhora na habilidade de distinguir atributos de voçoroca e não voçoroca. Atributos baseados na forma foram também fatores importantes na classificação. O comprimento da aresta mais longa de um polígono, a razão comprimento/largura e critério de ajuste retangular foram capazes de discriminar objetos estreitos a partir de uma vizinhança ou objetos largos, como muitas voçorocas consistiam de objetos longos e/ou lineares em um fator de escala igual a 50.

Perroy e outros autores (2010) realizaram um estudo comparando MDTs de uma voçoroca, gerados com dados obtidos por sistema ALS e TLS. A varredura com ALS foi realizada com espaçamento entre pontos de aproximadamente 1,5 m, possibilitando a produção de um MDT com resolução espacial de 1,5 m. A varredura com TLS foi realizada a partir de 37 pontos de instalação do equipamento (georreferenciados) e os dados foram processados gerando-se uma rede irregular de triangulação (TIN – *Triangulated Irregular Network*) com resolução espacial de 0,25 m e com erro máximo vertical de 0,05 m. Os dados foram validados com auxílio de um levantamento topográfico com uso de estação total. A borda da voçoroca foi medida usando DGPS (*Differential Global Positioning System*) com técnica cinemática. Os resultados mostraram que ambos MDTs, quando comparados com o produzido com os dados medidos com estação total, subestimaram a profundidade da voçoroca. Segundo os autores, o erro está fortemente relacionado com a densidade de pontos, principalmente nas áreas em que não houve retorno do sinal,

e com o espaçamento entre os mesmos. Para o sistema aerotransportado, a densidade é de mais de 1 ponto por  $m^2$ . Entretanto, a forma e o tamanho das voçorocas apresentam características bastante particulares. As paredes laterais íngremes e as seções transversais em forma de “v” produzem mudanças rápidas de elevação em curtas distâncias e, a menos que o instrumento seja direcionado diretamente sobre o eixo da voçoroca, o MDT resultante sempre irá subestimar as profundidades e, conseqüentemente, o volume. Para o sistema terrestre, a densidade média de pontos é significativamente maior e fornece informação mais detalhada. Em função do alcance de varredura e da orientação limitados dos sistemas terrestres, ocorrem dificuldades na coleta contínua de dados de voçorocas profundas, fazendo com que o sistema aerotransportado seja melhor para este tipo de investigação (PERROY *et al.*, 2010).

Johansen e outros autores (2012) desenvolveram uma base de regras para classificação de voçorocas, baseada em abordagem orientada a objeto, aplicada somente a dados altimétricos, provenientes de varredura a LASER aerotransportado. O objetivo do estudo foi o monitoramento da extensão e volume da voçoroca, bem como avaliar alterações temporais. Para tal, foram usados dados LiDAR dos anos 2007 e 2010 e observações de campo. Os dados altimétricos foram utilizados para gerar o MDT e um mapa de declividade com resolução espacial de 0,5 m. Realizaram uma segmentação com o algoritmo *chessboard*, usando tamanho do objeto igual a 5, seguida de segmentação multirresolução com fator de escala igual a 9, parâmetro de forma igual a 0,1 e fator de compacidade igual a 0,5. As voçorocas foram classificadas em fortes e fracas de acordo com a declividade. Um buffer de 25 pixels foi aplicado ao redor dos objetos classificados como borda de voçoroca de forma a preencher o centro das mesmas. A avaliação do resultado foi realizada em função de 300 pontos de validação amostrados a partir de uma ortofoto. A acurácia global foi de 92,3%, a acurácia do produtor foi de 93,9% e a do usuário de 98,2%, sendo a maior contribuição para os erros a presença de áreas inclinadas no terreno, principalmente quando localizadas próximas às voçorocas (erros de inclusão). A

mesma base de regras pôde ser usada para três voçorocas localizadas em regiões diferentes dentro da área de estudo, bem como para os dados das diferentes datas.

Usando análise orientada a objeto e dados multifonte, um estudo foi conduzido para fornecer informação sobre localização e dinâmica das voçorocas e o grau de degradação do solo (densidade da voçoroca). Para tal, foram usadas imagens provenientes dos sensores Ikonos-2 e GeoEye-1, bem como um MDS (Modelo Digital de Superfície) gerado a partir do par estereoscópico GeoEye. Índice de textura GLCM (*Gray Level Co-occurrence Matrix*), NDVI (*Normalized Difference Vegetation Index*) e declividade foram gerados e usados no processamento. Os dados foram segmentados pelo algoritmo de segmentação multirresolução, com auxílio do programa eCognition, e foram identificadas as áreas potenciais para ocorrência de voçorocas, em função da declividade e da textura. Os resultados obtidos mostraram que as bordas mais finas dentro de sistemas complexos de voçoroca foram melhor identificadas, quando comparadas às obtidas por digitalização manual. Além disso, a análise orientada a objeto proporcionou um mapeamento das voçorocas mais rápido e mais objetivo do que com os métodos tradicionais de classificação estatística. Como a identificação acurada de voçorocas não é possível sem dados adicionais ou conhecimento especialista, a adição de informação auxiliar, tal como propriedades geométricas (forma, dimensão, orientação e textura) e relação espacial com feições vizinhas, permite uma abordagem similar à abordagem cognitiva, usada em avaliação visual de imagens, mas de uma maneira controlada e quantitativamente reproduzível. A abordagem orientada a objeto permite tratar as feições de erosão como objetos espaciais, que podem ser caracterizados baseados não somente em suas propriedades geométricas, mas também na sua relação espacial com as feições vizinhas. Os autores salientam, ainda, que o potencial das análises de imagens orientadas a objetos para mapear feições erosivas do tipo voçoroca a partir de imagens óticas de alta resolução espacial (HRI – *high resolution imagery*) foi raramente explorado (SHRUTHI, KERLE e JETTEN, 2011 e 2012; SHRUTHI *et al.*, 2015; SHRUTHI,

2015). Entretanto, mesmo o método proposto sendo robusto, dados de HRI (nem sempre estão disponíveis, além de serem caros. Além disso, a seleção das características apropriadas dos objetos a serem utilizadas, bem como dos seus intervalos de valores, deve ser realizada de forma semiautomática, largamente empírica, implicando em subjetividade e requerendo adaptações quando a base de regras é usada para uma imagem e/ou região diferente.

Além da possível indisponibilidade de dados HRI, uma imagem de alta resolução não cobre extensas áreas na paisagem. Em função disso, um estudo foi conduzido usando um estéreo-par de imagens de média resolução espacial, do sensor ASTER, bem como um MDS produzido a partir da imagem. Foram consideradas as informações espectrais (bandas do verde, vermelho, infravermelho próximo, NDVI, brilho e máxima diferença), topográficas (MDS, declividade, aspecto, entre outros), de textura (homogeneidade, correlação, média, desvio padrão GLCM) e geométricas (área, comprimento/largura, ajuste retangular, assimetria, índice de forma, circularidade). Os dados foram segmentados com um fator de escala igual a 8, pelo método de segmentação multirresolução. A classificação foi realizada pelo algoritmo *random forests*, usando o pacote RF (linguagem e ambiente para computação estatística). As classes definidas foram: agricultura, floresta, solo exposto, área de pousio (não cultivada), encosta e fundo de vale da voçoroca. As melhores variáveis discriminantes da voçoroca foram NDVI, MDT, máxima diferença, brilho, declividade e outros derivativos topográficos. A acurácia global foi de 81%, sendo que ocorreram confusões entre as classes da voçoroca e de solo exposto. Os resultados mostraram que os dados ASTER podem ser usados para identificar as áreas de voçoroca, especialmente quando se trata de sistemas complexos (que abrangem grandes áreas) (SHRUTHI *et al.*, 2014).

Wang e outros autores, 2014 realizaram estudo para extrair a linha de borda de voçorocas, usando análise orientada a objeto, a partir de ortofoto de alta resolução espacial (0,25 m) e 10.220 pontos medidos em campo com GPS-RTK (*Real Time Kinematic*). Estes pontos foram usados para geração do MDT

(interpolados pelo método de krigagem, com resolução de 0,25 m), para avaliação da acurácia e também para o cálculo do volume. Foram consideradas, para a segmentação multirresolução e posterior classificação, características espectrais, geométricas e de textura. Na primeira segmentação foram usadas as características de média e contraste (relativas à textura GLCM), de razão de aspecto, área, índice de forma e a banda do vermelho. Foram usados como parâmetros o fator de escala igual a 20, parâmetro de forma igual a 0,9 e compacidade igual a 0,8. De acordo com os limiares definidos para a classificação (média GLCM  $\leq 107$ , vermelho  $\leq 146$  e borda relativa  $\geq 0,45$ ) os objetos foram classificados em não voçoroca e voçoroca. Como as voçorocas da área de estudo são cobertas por vegetação baixa e há a presença de campos de cultivo regulares e vegetação esparsa em torno das mesmas, as bordas não ficaram claramente distintas. Objetos pertencentes à área de cultivo foram erroneamente classificados como voçoroca. Em função disso, foram usados para distinguir as áreas de cultivo a banda do vermelho e o parâmetro de textura. Uma segunda segmentação foi então realizada, usando as bandas do vermelho e verde, fator de escala igual a 30, parâmetro de forma igual a 0,9 e compacidade igual a 0,6. Com base nas características espectrais, GLCM  $\geq 343$ , área igual a 10.000 e relação entre os objetos-imagem e a borda da imagem, nova classificação foi realizada. Como ainda restaram pixels classificados erroneamente, relativos a árvores frutíferas adjacentes à parte da voçoroca, uma terceira segmentação foi realizada, considerando-se apenas a banda do verde, com fator de escala igual a 30, parâmetro de forma igual a 0,8 e compacidade igual a 1. A classificação usou a banda do vermelho e o parâmetro de borda relativa. A borda extraída pela classificação final foi comparada aos dados medidos em campo, sendo que a diferença média entre os pontos extraídos e medidos foi de 0,3166 m. O volume foi calculado, adaptando-se uma superfície suposta original (antes da perda de solo), usando-se regressão linear, e subtraindo desta o MDT.

Um estudo aplicando algoritmos de árvores de decisão foi conduzido por Alkhasawneh e outros autores (2014), com a finalidade de determinar a



susceptibilidade a deslizamentos e movimentos de massa, em função de variáveis topográficas e geológicas. A avaliação de mapas de susceptibilidade permite prever futuros movimentos de massa e a tomada de medidas preventivas ou mitigatórias. O objetivo do estudo era determinar a melhor árvore de decisão capaz de especificar a importância de 21 fatores causadores de deslizamentos, dentre eles: cobertura vegetal, distância à linha de falha, ângulo e aspecto do declive, geologia, distância à rodovia/rua, rugosidade, elevação, textura do solo, área da superfície, distância à drenagem, cobertura do solo, curvatura cruzada. Esses fatores foram obtidos pelo processamento de um MDS com resolução espacial de 5m. Foram usados os modelos CHAID (*Chi-square Automatic Interaction Detector*), Exhaustive CHAID, CART (*Classification and Regression Tree*) e QUEST (*Quick-Unbiased-Efficient Statistical Tree*). Avaliando-se em função de dados de validação, foram obtidas as seguintes acurácias para os diferentes modelos: Exhaustive CHAID = 82%, CHAID = 81,9%, CART = 75,6% e QUEST = 74%. Segundo todos os modelos, os cinco fatores mais importantes foram: ângulo do declive, distância à drenagem, área da superfície, aspecto do declive e curvatura cruzada.

### 3.2 CLASSIFICAÇÃO BASEADA EM RELAÇÕES DE HIERARQUIA E ÁRVORES DE DECISÃO

Os objetos do mundo real são classificados para que possuam um sentido, reduzindo uma multiplicidade de fenômenos para um número relativamente pequeno de classes gerais. A classificação refere-se à definição de categorias ou classes de objetos e também à atribuição ou alocação de objetos individuais para essas classes (TSO e MATHER, 2009).

Um estudo que apresenta a classificação por árvores de decisão e a exploração de múltiplos tipos de dados, para classificação de ambiente urbano, foi desenvolvido por Araki (2005). O objetivo era efetuar a classificação de imagens de alta resolução espacial, com base no pixel, combinando informações espectrais,

altimétricas e de dados auxiliares. Foram utilizados: imagem Quickbird, dados altimétricos obtidos com ALS e carta topográfica na escala 1:2.000. Os dados foram classificados usando o algoritmo J4.8 de indução de árvores de decisão, com o pacote WEKA (*Waikato Environment for Knowledge Analysis*). Informações auxiliares foram geradas a partir dos dados originais, dentre elas o NDVI, diferença entre as bandas 3 e 1 ( $Dif31 = B3 - B1$ ), diferença entre as bandas 1 e 3 ( $Dif13 = B1 - B3$ ), declividade, MDSN (Modelo Digital de Superfície Normalizado) e imagem de intensidade do ALS. A maior acurácia do usuário obtida foi de 83,33% e a maior acurácia do produtor foi 91,67%. O autor comprovou a importância da inserção de dados auxiliares na classificação de imagens de alta resolução espacial, bem como do uso do método de árvores de decisão para a seleção dos atributos que mais contribuem na discriminação entre as classes.

Luz (2011) desenvolveu um estudo para a classificação de subtipologias de Floresta Ombrófila Mista. Para tal, foi utilizada imagem Ikonos-II, a qual foi segmentada pelo algoritmo de segmentação multirresolução, com auxílio do programa eCognition. A partir dos objetos segmentados foram gerados atributos espectrais, de forma e textura. Usando-se os algoritmos J4.8, SimpleCART, RandomTree e RepTree de indução de árvores de decisão, com auxílio do pacote WEKA, foram determinados os atributos mais relevantes na discriminação entre as classes, bem como seus intervalos de valores. A classificação foi então realizada com base na árvore de decisão gerada. Os melhores resultados, após avaliação das classificações, foram obtidos com a aplicação do algoritmo SimpleCART (acurácia global de 83,36%). Segundo a autora, os resultados obtidos mostraram-se satisfatórios, principalmente levando-se em conta a alta similaridade espectral das classes de cobertura florestal de interesse, o que confirma a hipótese de que a análise orientada a objetos aliada aos dados espectrais, em uso conjunto com algoritmos de árvore de decisão, pode melhorar os resultados da classificação de imagens de alta resolução espacial.

Leonardi (2010) realizou estudo, para a classificação da cobertura do solo

urbano, a partir de dados espectrais (imagem Ikonos) e altimétricos (ALS). A metodologia proposta utilizou abordagens cognitivas (rede semântica multinível, lógica fuzzy, classificação orientada a objeto) e técnicas de mineração de dados (árvores de decisão). Os dados foram segmentados pelo algoritmo de segmentação multirresolução. Para a mineração dos dados foi utilizado o algoritmo J4.8 (implementado no pacote WEKA) e dois bancos de dados foram gerados, um contendo os atributos dos dados altimétricos e outro sem contê-los, a fim de avaliar a significância dos dados altimétricos na acurácia da classificação de cobertura do solo urbano. A partir da árvore de decisão obtida foram realizadas três classificações: uma com a árvore obtida e com os dados altimétricos, outra sem os dados altimétricos, e uma terceira com um refinamento da árvore obtida automaticamente. Utilizando os dados altimétricos, o autor obteve acurácia global de 0,7640 e índice kappa de 0,7344. Sem os dados altimétricos, a acurácia global foi de 0,5920 com índice kappa de 0,5376. A classificação com a rede semântica refinada proporcionou acurácia global de 0,78 e índice kappa de 0,7531. O autor verificou que a diferença entre as classificações obtidas com e sem os dados altimétricos é significativa. O autor enfatiza que as técnicas de mineração de dados para a exploração de grande quantidade de informações mostraram-se imprescindíveis, pois contribuíram para a determinação de quais seriam os melhores atributos e seus respectivos limiares, dado o elevado número de atributos (espectrais, geométricos, topológicos e texturais). A integração de dados de altura dos objetos às imagens multiespectrais auxiliaram na distinção entre vegetação arbórea e rasteira, bem como na discriminação das classes de cobertura de edificações que possuem altura média superior à das classes que se localizam ao nível do terreno.

Estudo similar ao de Leonardi (2010) foi desenvolvido por Pinho e outros autores (2012), para a classificação de áreas urbanas, usando apenas dados espectrais. A metodologia foi baseada em análise orientada a objeto, sendo os dados segmentados pelo algoritmo de segmentação multirresolução, com auxílio do programa eCognition. A seleção de atributos discriminantes foi realizada por meio de

mineração de dados, usando o algoritmo C4.5 do pacote WEKA para indução da árvore de decisão. Onze classes foram definidas. A acurácia global obtida foi de 71,91%, sendo que as maiores confusões ocorreram entre as classes solo exposto e telhados cerâmicos, pavimento asfáltico e telhado de asbesto, grama e árvores. Os autores salientam que os resultados satisfatórios devem-se, provavelmente, à representação do conhecimento em forma de redes hierárquicas, o que permite o estabelecimento das relações entre classes ou grupos de classes. A segmentação multirresolução permitiu o uso de informação contextual, espectral e topológica em diferentes escalas e as técnicas de mineração de dados aumentaram a velocidade do processamento e reduziram a natureza empírica de seleção dos atributos na construção da rede hierárquica.

Ghose, Pradhan e Ghose (2010) compararam os resultados de duas classificações realizadas pelo método da máxima verossimilhança e por árvore de decisão. Para tal, utilizaram uma imagem do sensor IRS - *Indian Remote Sensing* (resolução espacial de 23 m) e desenvolveram um algoritmo para explicitar a árvore de decisão formulada. A árvore de decisão foi elaborada em função da matriz de separabilidade identificada para seleção das bandas mais apropriadas para discriminação das classes. A acurácia total foi de 98% com o algoritmo implementado e de 95% para o método da máxima verossimilhança.

Sharma, Ghoshi e Joshi (2013) realizaram estudo comparando classificações realizadas com árvore de decisão e com os métodos ISODATA (*Iterative Self-Organizing Data Analysis*) e máxima verossimilhança. Para tal, usaram imagem Landsat 5-TM, o algoritmo J4.8 de indução de árvore de decisão do pacote WEKA e o programa Erdas. Seis classes foram definidas. Usando a árvore de decisão a acurácia global obtida com a classificação foi de 90% e o índice kappa de 0,88. Pelo método ISODATA a acurácia global foi de 57,5% e o índice kappa de 0,49. Usando o método da máxima verossimilhança a acurácia global foi de 76,67% e o índice kappa de 0,72. Os autores concluíram que a classificação obtida com a aplicação da árvore de decisão forneceu uma melhor representação visual.

## 4 MATERIAIS E MÉTODOS

### 4.1 ÁREAS DE ESTUDO

Para o desenvolvimento deste estudo, duas áreas foram selecionadas, uma em Uberlândia-MG e outra em Queensland-Austrália, descritas a seguir.

#### 4.1.1 Área de estudo 1 – Uberlândia-MG

A área de estudo 1 (A1) está localizada na Fazenda Experimental do Glória, a qual pertence à Universidade Federal de Uberlândia. A fazenda encontra-se na zona rural do município de Uberlândia-MG (figura 6).

A voçoroca da área de estudo está localizada em uma área de contato geológico entre o Grupo Bauru e o Grupo São Bento, na qual ocorrem resquícios de arenitos intercalados por lentes de siltitos e argilitos. A voçoroca está localizada em região de média para baixa vertente e sobre um contato de litologias mais permeáveis com outras menos permeáveis, havendo extensa área de alimentação do lençol freático localizado a montante, o que reflete em condições ideais para que a água do lençol exude nesta área. A presença destas exudações mantém o canal da voçoroca alimentado com água durante todo o ano. Durante o período chuvoso o lençol é abastecido constantemente, o que reflete no aumento do número de exfiltrações, e, conseqüentemente, no aumento da taxa de vazão (ALVES, 2007).

O domínio morfoclimático e fitogeográfico, ao qual pertence o município de Uberlândia, é o dos Chapadões recobertos por cerrados e penetrados por florestas-galerias (LEAL e RODRIGUES, 2011). Em todas as suas porções, verifica-se que a vegetação predominante é o Cerrado e suas variáveis, como veredas, campos limpos, campos sujos ou cerradinhos, cerradões, matas de várzea, matas de galeria ou ciliares e matas secas ou mesofíticas (SMPU, 2010).

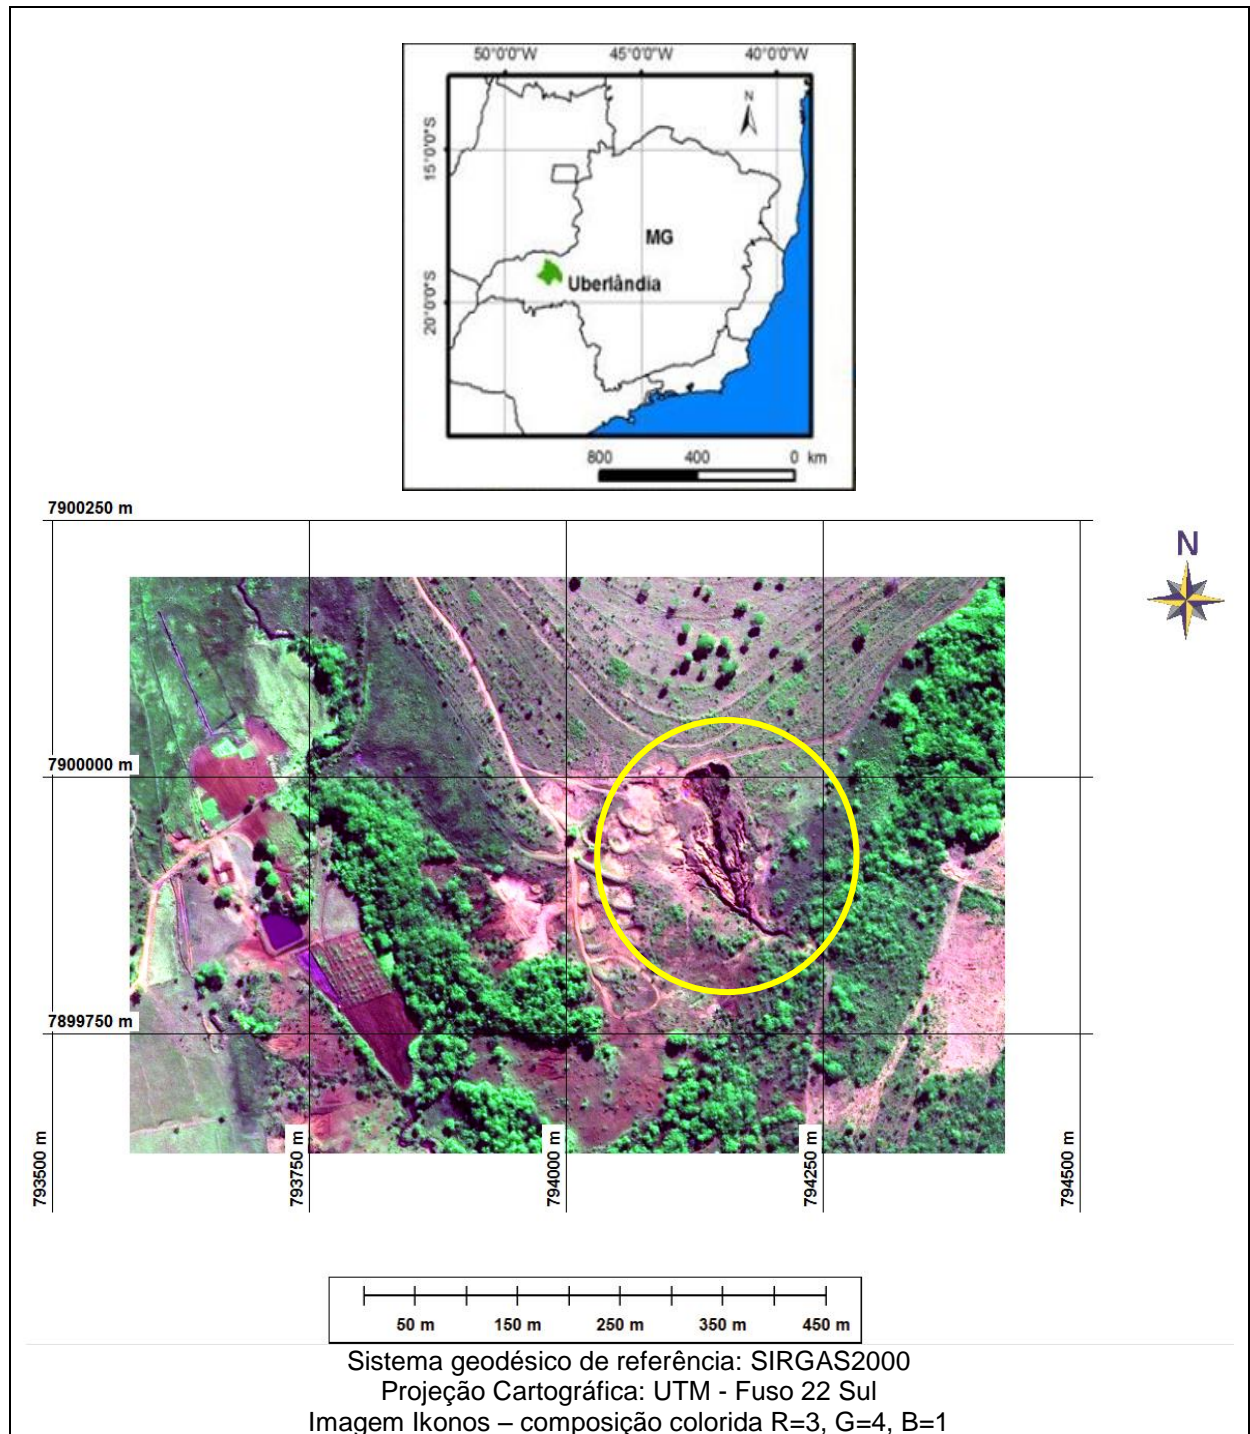


FIGURA 6 – LOCALIZAÇÃO DA ÁREA DE ESTUDO A1

FONTE: A AUTORA, 2015

OBS: VOÇOROCA COMPREENDIDA NO CÍRCULO AMARELO

Três unidades geomorfológicas podem ser distinguidas no município: área de relevo dissecado, área de relevo intensamente dissecado e área de relevo com topo plano. Dentre os três compartimentos geomorfológicos, o de relevo dissecado é onde os processos erosivos são mais intensos (LEAL E RODRIGUES, 2011).

A área de estudo está localizada na vertente de uma colina que apresenta uma declividade média de 6%, tendo um comprimento de rampa total de aproximadamente 1.000 m e forma predominantemente convexa. Os últimos 750 m, partindo de alta para baixa vertente, apresentam uma descontinuidade na formação do escoamento superficial, fato que faz com que cerca de 400 m do comprimento da vertente funcionem como possível área de contribuição. Nos outros 350 m da vertente ocorre a incisão da voçoroca (ALVES, 2007). A região faz parte da bacia hidrográfica do Córrego Glória, que é tributário do Rio Uberabinha. O Rio Uberabinha é integrante da bacia do Rio Araguari e, em conjunto com seus afluentes, constitui o manancial utilizado para o abastecimento de água da cidade (SMPU, 2010). A figura 7 ilustra a localização dos canais principal e secundário, bem como os direcionamentos dos registros fotográficos efetuados no local e as dimensões da voçoroca. A voçoroca apresenta um canal principal, um secundário e outros diversos canais conectados ao principal e ao secundário. O canal principal tem aproximadamente 200 m de extensão (medida “A” – na figura 7), altura em torno de 8 m e largura que varia de 50 m (medida “B” – na figura 7) na região de montante a 70 cm na foz (medida “C” – na figura 7).

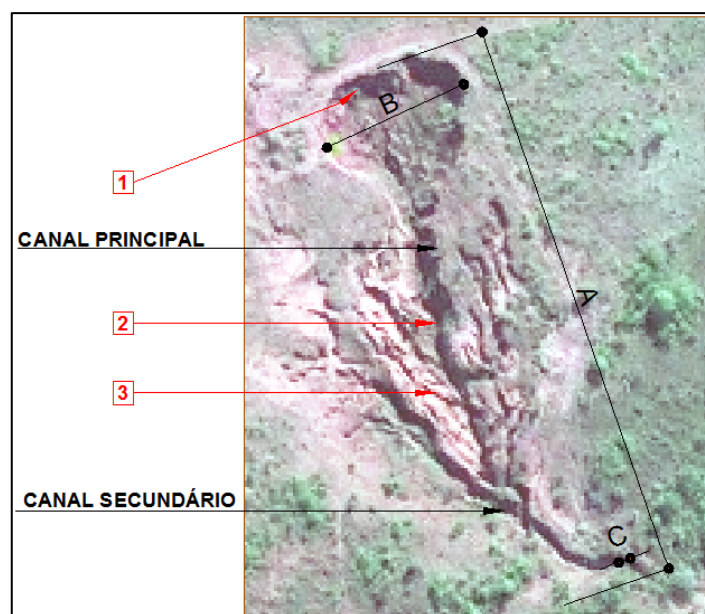


FIGURA 7 – DIRECIONAMENTO DOS REGISTROS FOTOGRÁFICOS, CANAIS E DIMENSÕES DA VOÇOROCA  
 FONTE: A AUTORA, 2015



A figura 8 apresenta os registros fotográficos evidenciando a cabeceira, canal principal e dígitos da voçoroca. Os registros foram efetuados durante visita técnica realizada no local, em dezembro de 2008. É possível perceber a variação espacial em largura e profundidade, tanto da cabeceira como dos canais e dígitos, bem como a mistura de materiais constituintes como solo, água e vegetação, aspectos estes relevantes na classificação de voçorocas.




FIGURA 8 – REGISTROS FOTOGRÁFICOS DA ÁREA DE ESTUDO A1  
 FONTE: A AUTORA, 2015

Durante todo o ano existe água no fundo do canal da voçoroca, proveniente de exudações do lençol freático. O canal secundário permanece com vazão



constante em seu leito aproximadamente 5 meses por ano, caracterizando-o como voçoroca com fluxo de lençol intermitente. As ramificações menores e menos profundas, juntamente com as ravinas, não apresentam exudação do lençol freático, entrando em funcionamento apenas durante os eventos chuvosos (ALVES, 2007).

Segundo a classificação de Köppen, o clima de Uberlândia tem a classificação Cwa, ou seja: C - Temperado, ou também denominado Mesotérmico (estações de verão e inverno bem definidas); w - Chuvas de verão; a - verões quentes, com temperatura média do ar no mês mais quente superior ou igual a 22°C. A temperatura média varia entre 19°C e 27°C (SMPU, 2010).

O regime pluviométrico é tropical, isto é, chuvas de verão iniciando-se em outubro/novembro (estação úmida) e tornando-se mais raras a partir de março/abril (estação seca). Segundo Silva e Assunção (2004), a pluviosidade média está em torno de 1.500 mm por ano. As precipitações máximas e mínimas históricas ocorridas até 2010 foram de 2.207,10 mm e de 1.012,60 mm, respectivamente (SMPU, 2010).

Dentro do período chuvoso ocorrem duas fases distintas, uma que apresenta precipitações mais intensas e outra com intensidade inferior e precipitações mais duradouras. Durante as precipitações intensas aumentam a formação dos deslizamentos e de diversos tipos de processos erosivos (ALVES, 2007).

Quanto ao uso do solo na região, o mesmo foi profundamente afetado por programas de governo que incentivaram a ocupação das áreas de cerrado para uso agropecuário. Os programas PRODECER (Programa de Cooperação Nipo-Brasileiro para o Desenvolvimento dos Cerrados), PADAP (Programa de Assentamento Dirigido do Alto Parnaíba) e PROÁLCOOL foram responsáveis pelo direcionamento de recursos para os cerrados. Esses programas trouxeram transformações na economia regional, pois extensas áreas de chapadas foram tomadas pela atividade agrícola mecanizada e quimificada, trazendo as agroindústrias para as regiões abrangidas pelos programas. Em 1984, o Relatório sobre Avaliação do Impacto Ambiental na Região do Cerrado apontou empobrecimento genético, compactação e

erosão dos solos, contaminação química das águas e da biota, rebaixamento do lençol freático nos vales em veredas, onde as planícies aluviais estão sendo drenadas pelos projetos de irrigação (BACCARO, 2010).

Dentre os estudos desenvolvidos sobre a área de estudo, os mesmos concentram-se na caracterização e monitoramento da voçoroca, bem como na avaliação de medidas de contenção dos processos erosivos já instalados. Mensurações sobre as dimensões e forma da voçoroca foram realizadas usando método de estaqueamento e levantamento com receptores GPS (LEAL e RODRIGUES, 2011). O monitoramento por sensoriamento remoto, quando usado, foi realizado com fotografias aéreas analógicas (BEZERRA, GUERRA e RODRIGUES, 2011; LEAL e RODRIGUES, 2011), imagens ópticas orbitais dos sensores Quickbird e ASTER, imagem ENVISAT ASAR e MDS derivado de dados SRTM (VRIELING, RODRIGUES e STERK, 2005), entretanto, com técnicas de interpretação visual ou classificação automática com base no pixel.

#### 4.1.2 Área de estudo 2 – Queensland - Austrália

A área de estudo 2 (A2) está localizada na bacia hidrográfica do rio Burdekin, em Queensland - Austrália (figura 9). A área foi selecionada em virtude da disponibilidade de dados espectrais e altimétricos de alta resolução espacial e da presença de voçorocas na região.

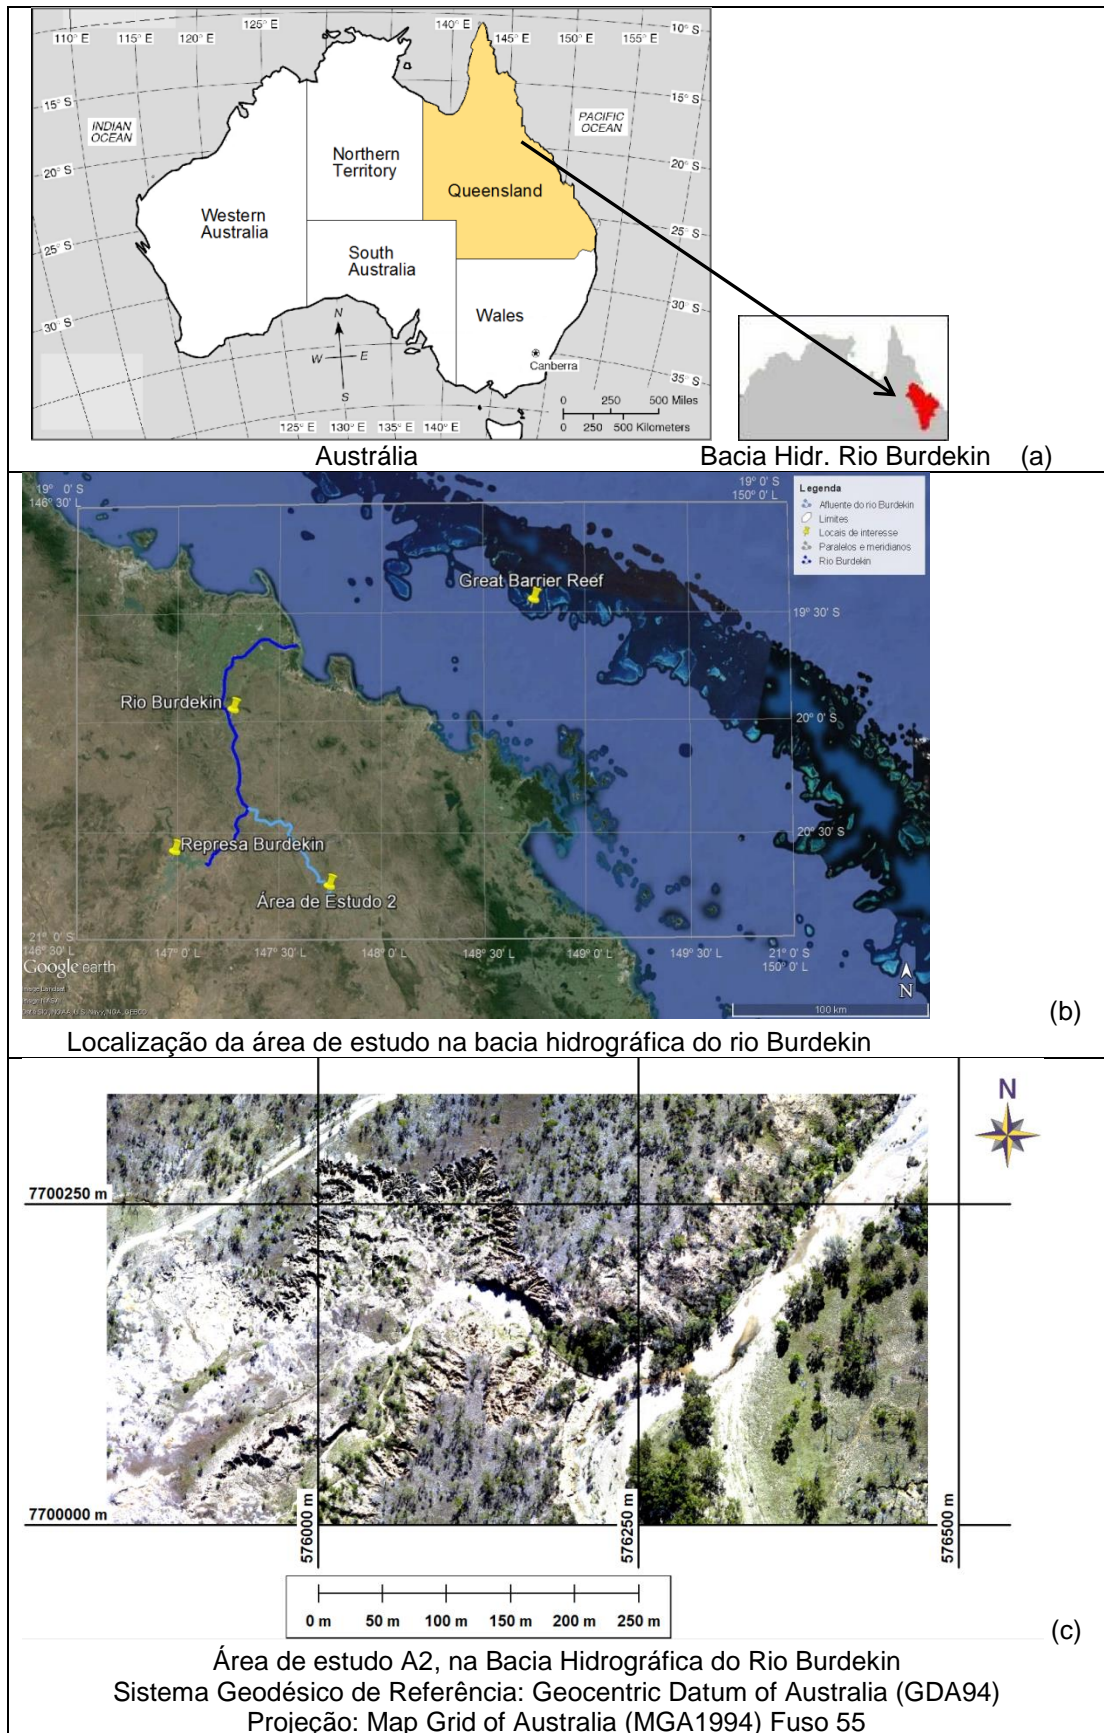


FIGURA 9 – LOCALIZAÇÃO DA ÁREA DE ESTUDO A2

FONTE: a) ADAPTADO DE HARRISONBURG HIGH SCHOOL (2015); b) e c) A AUTORA (2015)

A bacia hidrográfica do rio Burdekin está localizada ao norte de Queensland, cobrindo uma área de aproximadamente 130.000 km<sup>2</sup>. O clima na região é o tropical seco, com média anual de precipitação variando de 500 a 1500 mm por ano, com maior frequência entre os meses de dezembro e abril. O uso do solo mais frequente é para pastejo. O rio deságua na grande barreira de corais (*Great Barrier Reef*), a qual corresponde ao maior sistema de recifes de corais do mundo, sendo grande parte do sistema protegido pelo *Great Barrier Reef Marine Park*. A bacia do rio Burdekin é responsável por um terço do total da descarga anual de todas as bacias hidrográficas que deságuam dentro do lago do *Great Barrier Reef*. O uso do solo para pastejo implica no transporte de aproximadamente 90% dos sedimentos e nutrientes para a grande barreira de corais. Além disso, a presença de muitas áreas de voçorocamento aumenta a sedimentação nos afluentes da bacia (GILAD, DENHAM e TINDALL, 2012; NWC, 2015).

## 4.2 MATERIAIS

Para realização deste estudo foram usados dados espectrais, provenientes de ortofotos e de imagem de satélite, e dados altimétricos, provenientes de varredura com sistemas ALS.

Para a área de estudo A1, foram usados os seguintes dados de sensoriamento remoto:

- Uma imagem do sensor Ikonos II, de 2003;
- Dados altimétricos e de intensidade obtidos com ALS, de 2004.

As principais características do satélite Ikonos II são listadas no quadro 1.

Resolução espacial	Pancromática = 1 m (nadir) Multiespectral = 4 m (nadir)
Resolução espectral	Pancromática (Pan) = 526 a 929 (nm) Multiespectral (MS) = Banda 1: 445 a 516 (nm) Banda 2: 506 a 595 (nm) Banda 3: 632 a 698 (nm) Banda 4: 757 a 853 (nm)
Resolução Radiométrica	11 bits

QUADRO 1 - CARACTERÍSTICAS DO SENSOR IKONOS II  
FONTE: JENSEN, 2009

A imagem do sensor Ikonos II foi capturada em 4 de julho de 2003 e cedida para o desenvolvimento deste estudo, apresentando correção pelos parâmetros orbitais e reamostrada por convolução cúbica. Foram disponibilizadas as bandas RGB (*Red, Green e Blue*) e NIR (*Near InfraRed*) fusionadas com a PAN (pancromática), com resolução espacial de 1 m e radiométrica de 11 bits.

Quanto aos dados altimétricos, os mesmos são provenientes de varredura com o equipamento ALTM 2025 (*Airborne LASER Terrain Mapper*) do fabricante canadense Optech Inc. Os voos foram efetuados de janeiro a junho de 2004, sobre o município de Uberlândia-MG, com altura de voo de 1.000 m e frequência de 33 Hz. Os dados possuem densidade média de 1,89 pontos por m<sup>2</sup>, distância média entre pontos de 1,23 m e qualidade planimétrica após processamento (segundo o fabricante) de 0,5 m a 1,0 m (1/1000 x H a 1/2000 x H, sendo H a altura de voo). O sensor ALTM 2025 fornece dados com precisão altimétrica de aproximadamente 0,15 m para dados brutos. As principais características do sensor estão listadas no quadro 2.

Altitude Operacional	250 a 3.000 m
Acurácia Altimétrica	15 cm a 1200 m; 25 cm a 2000 m (1 sigma)
Resolução: Range resolution	1 cm
Ângulo do Scanner	Variável de 0 a $\pm 20^\circ$
Largura: Swath width	Variável de 0 a 0,68 x altitude
Frequência do escâner	Variável, depende do ângulo de varredura; por exemplo, 28 Hz para $\pm 20^\circ$ de varredura
Acurácia Horizontal	Melhor que 1/2000 x altura de voo
Taxa média de repetição do LASER	25 kHz
Divergência do Feixe	Variável, 0,2 mrad (1/e) ou 1,0 mrad
Comprimento de onda do LASER para imagem de intensidade	1046 nm (infravermelho próximo)

QUADRO 2 - CARACTERÍSTICAS DO SENSOR OPTECH ALTM 2025  
FONTE: ADAPTADO DE LEONARDI (2010)

Para a área de estudo A2, foram usados os seguintes dados de sensoriamento remoto:

- Mosaico de ortofoto, com resolução espacial de 50 cm e radiométrica de 8 bits, bandas do visível (azul, verde e vermelho), e
- Dados altimétricos e de intensidade obtidos com ALS.

Os dados da varredura com ALS foram efetuados com o sensor Riegl LMS-Q560, cujas especificações estão listadas no quadro 3, cedidos para o desenvolvimento deste estudo, tendo sido fornecido o arquivo com os valores das coordenadas tridimensionais e de intensidade (arquivo LAS). Os dados ALS e a ortofoto foram adquiridos durante o mesmo voo e, por isso, encontram-se georreferenciados.

Mecanismo de varredura	rotating polygon mirror
Altitude Operacional	de 50 a 550 m
Velocidade de voo	198 km/h
Frequência do pulso	200 kHz
Sobreposição	50%
Ângulo de varredura (FOV – Field of View)	45°
Largura da faixa	456m
Frequência do escâner (taxa de varredura)	110 Hz
Espaçamento entre pontos: ao longo da linha de voo transversal à linha de voo	0,50m 0,50m

QUADRO 3 – CARACTERÍSTICAS DO SENSOR RIEGL LMS-Q560  
FONTE: RIEGL LASER MEASUREMENTS SYSTEM (2010)

Os processamentos foram realizados com auxílio dos programas computacionais ENVI (*The Environment for Visualizing Images*) 4.7, ALDPAT (*Airborne LiDAR Data Processing and Analysis Tools*), eCognition Developer 8.8 e ARCGIS 9.

### 4.3 METODOLOGIA

Para a confirmação da hipótese estabelecida neste trabalho, os dados das duas áreas de estudo foram submetidos à metodologia ilustrada no diagrama a seguir.

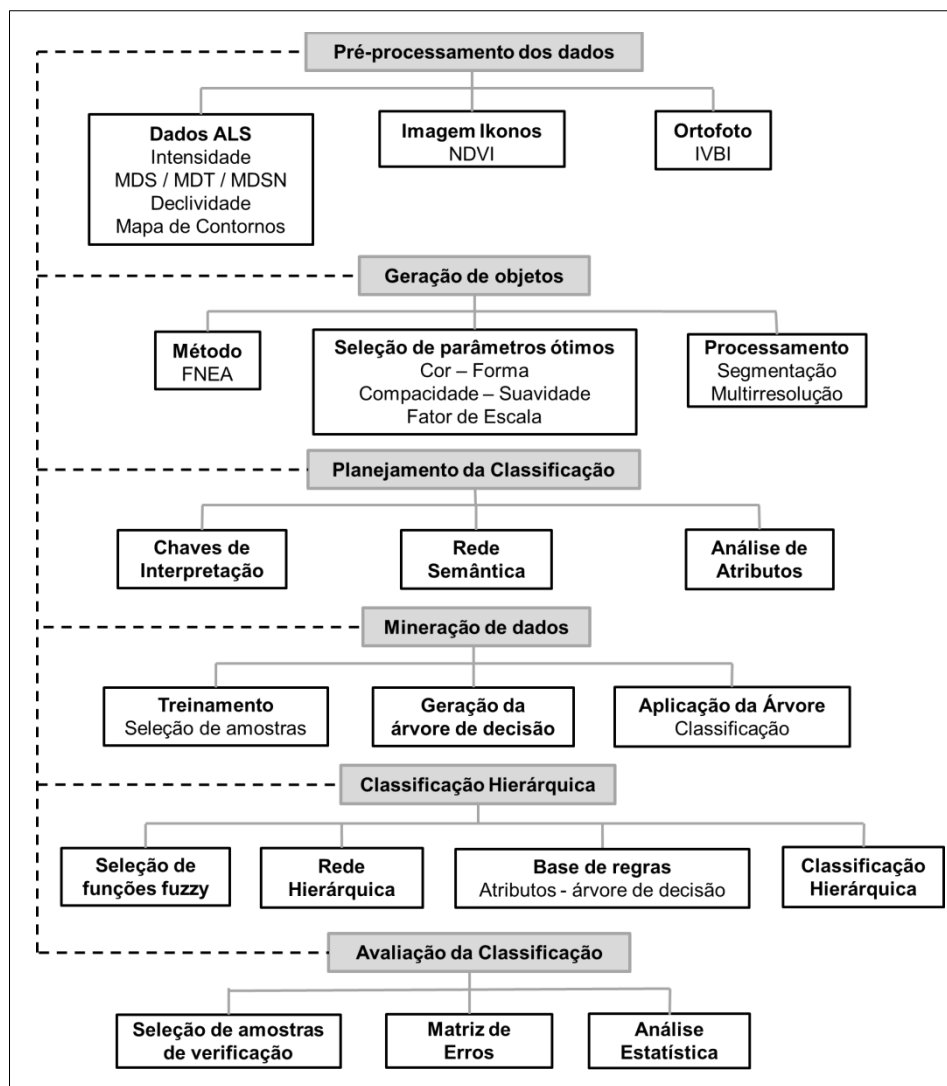


FIGURA 10 – DIAGRAMA COM AS ETAPAS METODOLÓGICAS  
FONTE: A AUTORA (2015)

#### 4.3.1 Processamento das nuvens de pontos ALS e geração de NDVI

Anteriormente ao processamento das imagens usando abordagem orientada a objeto, fez-se necessário o pré-processamento dos dados visando a rasterização dos dados altimétricos e a geração de produtos derivados, como MDT, MDSN, mapa de declividade, mapa de curvas de nível e NDVI. O pré-processamento foi realizado conforme ilustra o diagrama da figura 11, e as etapas são detalhadas a seguir.

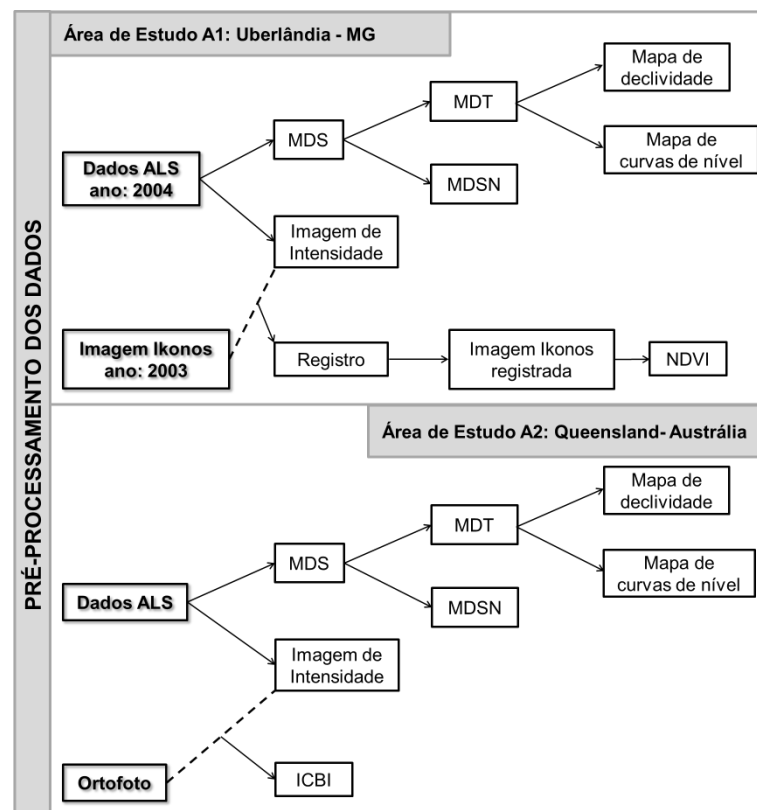


FIGURA 11 – DIAGRAMA DO PRÉ-PROCESSAMENTO DOS DADOS  
FONTE: A AUTORA (2015)

#### A) PROCESSAMENTO DAS NUVENS DE PONTOS ALS:

Para que os dados altimétricos possam ser submetidos ao processamento digital de imagens é necessário transformá-los para o formato raster. Para tal, os dados foram interpolados de forma a gerar uma grade regular de pontos. Para a área de estudo A1, a grade gerada tem resolução espacial de um metro, compatível com a imagem Ikonos e com a distância média entre pontos (1,23 m). Para a área



de estudo A2 a grade gerada tem resolução espacial de 50 cm, compatível com a ortofoto e o espaçamento entre pontos. Para gerar a imagem raster, identifica-se a coordenada X mais à esquerda e Y mais acima para que seja atribuída ao primeiro pixel. Identificando-se a coordenada X mais à direita é possível determinar a largura da área imageada e, a partir da coordenada Y mais abaixo, se determina o comprimento da mesma. A partir da largura, comprimento e da resolução espacial pré-determinados, determina-se o tamanho da grade regular, em linhas e colunas, que abrangerá toda a área da varredura. Os valores de altitude e intensidade são então interpolados, em função das coordenadas planimétricas que possuem e da posição que deverão ocupar na grade regular. Os produtos resultantes desse processamento são a imagem de intensidade e o MDS. O procedimento foi realizado usando-se interpolação linear. O MDS contém informação de elevação das feições naturais e artificiais que se encontram acima da superfície nua do terreno, como edificações, árvores e torres de energia.

O MDT pode ser gerado pelo procedimento acima descrito, usando-se os mínimos valores de retorno do ALS. Para arquivos LAS é possível selecionar qual pulso será usado para a geração do MDS ou do MDT (dependendo do pulso utilizado).

Para a área de estudo A1, o MDT gerado com os mínimos valores não apresentou apenas as informações ao nível do terreno, em virtude da presença de áreas densas de vegetação arbórea. Nestas áreas de densa cobertura vegetal, mesmo os mínimos valores de retorno não correspondem ao chão, pois o pulso LASER não conseguiu ultrapassar os objetos até chegar ao solo. Isto acarreta erros no MDSN, a ser gerado em função do MDT, e usado na classificação de vegetação arbórea, por exemplo. Acarreta, ainda, erros nos mapas de curvas de nível e de declividade, gerados a partir do MDT. Além disso, o contorno da voçoroca não ficou bem delineado. Devido a isso, foi necessária a realização da filtragem da nuvem de pontos, de forma a se obter o MDT. Para a geração do MDT foram testados os filtros implementados no aplicativo ALDPAT.

O ALDPAT é um programa desenvolvido pelo IHRC (*International Hurricane Research Center*) da Universidade Internacional da Florida e que possui diversos algoritmos implementados para filtragem de dados ALS, os quais servem para classificar e separar objetos no solo e acima do solo. A lógica para estes algoritmos de filtragem é que a mudança de elevação no terreno é, frequentemente, gradual em uma vizinhança, enquanto que entre construções ou árvores e o terreno a mudança de elevação é muito ampla. As medidas para filtragem dos dados incluem declividade/inclinação da rampa, variação de elevação e distância até uma superfície adaptada regionalmente. Os algoritmos de filtros disponíveis são: ETEW Filter; Morph Filter; Morph2D Filter; MorphCircle Filter; Slope Filter; Polynomial Filter; Polynomial 2 Surface Filter e Adaptive TIN Filter (ZHANG e CUI, 2007). Vale ressaltar que não existem filtros perfeitos que consigam identificar todas as formas topográficas sem erros, devido à complexidade da superfície terrestre. Em função disso, selecionou-se para a área de estudo A1 o MDT que apresentou a melhor definição do contorno da voçoroca, em detrimento da filtragem dos outros objetos, como as árvores. O melhor MDT para a região da voçoroca foi obtido com a aplicação do filtro ATIN (*Adaptive TIN Filter*).

Para o filtro ATIN, devem ser definidos limiares de controle do processo de filtragem. Esses limiares são uma distância de referência entre as faces do TIN e pontos a serem avaliados, e um ângulo de referência entre as faces do TIN e as direções entre os vértices do TIN e os pontos a serem avaliados. Os pontos a serem avaliados devem pertencer ao domínio de cada face triangular. Ambos os limiares, quando não excedidos, permitem classificar pontos da nuvem como pertencentes ao terreno. A hipótese assumida pelo método de filtragem ATIN é que o relevo, independentemente do tipo de área associada (florestal, rural ou urbana), deve variar suavemente. Assim, assumindo-se que as discontinuidades são ocasionais, os limiares angular e de distância podem ser calculados a partir de todos os pontos da nuvem ALS, considerando-se que os mesmos devem refletir o fato de que a superfície possui comportamento suave (DAL POZ, 2013).

Neste filtro, uma superfície, representada por uma rede irregular triangular (TIN) é conectada a partir de baixo aos pontos de LASER distribuídos aleatoriamente (figura 12a). A superfície se adapta aos pontos e novos pontos são adicionados somente se eles atingirem determinados limiares de parâmetros derivados dos dados. Os limiares dos parâmetros são estimados a partir dos dados e mudanças durante o processo de filtragem. O algoritmo é um processo iterativo onde uma TIN grosseira, consistindo de pontos-sementes iniciais, é densificada. O processo pode ser descrito como (AXELSSON, 2000):

- cálculo inicial dos parâmetros usando todos os dados;
- seleção de pontos-semente;
- densificação iterativa da TIN:
  - cálculo dos parâmetros para cada iteração a partir dos pontos incluídos na TIN, e
  - adição de pontos à TIN, se eles estiverem abaixo dos valores limiares
- continua até que todos os pontos sejam classificados como solo ou objeto.

Os pontos semente são selecionados dentro de uma grade definida pelo usuário, sendo que a largura da grade é baseada no tipo mais largo de estrutura, por exemplo, uma construção que esteja presente na cena. Valores entre 50 e 100 m apresentam-se como uma boa seleção. Os pontos sementes são selecionados tendo por base o maior objeto elevado (por exemplo, um edifício) presente na cena a ser analisada. Dessa forma, assumindo-se que o relevo varia pouco dentro de cada célula da malha e que pelo menos um ponto foi amostrado no terreno, o ponto mais baixo em cada célula da malha é selecionado como ponto semente. Este procedimento permite selecionar  $n$  pontos semente, sendo  $n$  o número de células na malha selecionada. Uma TIN inicial é então gerada com  $n$  vértices (DAL POZ, 2013).

Para cada iteração, um ponto é adicionado, de cada vez, em cada lado da TIN, se ele satisfizer os critérios com base nos parâmetros-limite calculados. As

distâncias aos planos de cada lado e os ângulos aos nós são os principais valores comparados. Para cada ponto a ser avaliado são calculados 3 ângulos ( $\alpha$ ,  $\beta$  e  $\gamma$ ) (figura 12b) entre a face da TIN e as três direções ligando os vértices da face triangular e o ponto a ser avaliado; e a distância  $d$  entre o ponto a ser avaliado e a face triangular. O ponto em análise é considerado como de terreno se, e somente se, a distância  $d$  for menor que o limiar de distância e os ângulos  $\alpha$ ,  $\beta$  e  $\gamma$  forem menores que o limiar angular. O processo é aplicado a todos os pontos da nuvem e, sequentemente, os limiares angular e de distância são reestimados, com base nos pontos classificados como de terreno. Uma nova TIN é gerada com todos os pontos classificados como de terreno e os pontos não classificados anteriormente são submetidos a um novo ciclo de filtragem. Estas iterações são repetidas até que não haja mais nenhum ponto que possa ser classificado como de terreno. Os parâmetros-limite para estes valores são computados a partir dos dados a cada iteração. O algoritmo para densificação é válido para superfícies contínuas, como as paisagens normais. Superfícies descontínuas, as quais são mais frequentes em áreas urbanas, são mais difíceis de processar. Bordas são facilmente cortadas se os valores-limite são excedidos (figura 12c) (AXELSSON, 2000).

Usando-se o programa ALDPAT, devem ser configurados os seguintes parâmetros (ZHANG; CUI, 2007):

- *Cell size* (tamanho de célula): tamanho de célula de uma grade para analisar os dados brutos. Cada célula contém um ponto LIDAR de elevação mínima entre todos os pontos que caem dentro da célula.

- *Z difference* (diferença em Z): o limiar usado para comparar a distância de um ponto a um ponto abaixo da superfície TIN. Se a distância é menor que o limiar, o ponto é adicionado ao conjunto de dados ao nível do solo.

- *Angle Threshold* (limiar de ângulo): o valor padrão é zero quando nenhum ângulo limiar é usado.

- *Init TriGrid size* (tamanho inicial da TriGrid): o tamanho inicial de uma grade usada para selecionar pontos de semente, para o conjunto de dados no terreno. Um

ponto com uma elevação mínima dentro de uma célula da grade é selecionado como um ponto semente.

- *Tile X Width*: a largura de um retângulo para a aplicação do filtro ATIN. A triangulação Delaunay de pontos ALS para uma grande área é demorada. A fim de reduzir o tempo de computação, o filtro ATIN divide o conjunto de dados em pequenos retângulos cujos tamanhos são determinadas por X largura e Y altura.

- *Tile Y Height*: a altura do retângulo para aplicação do filtro ATIN.

- *Tile Buffer*: tamanho do buffer para um retângulo. Um buffer é criado para cada pequeno retângulo para assegurar a consistência dos resultados da filtragem para aqueles pontos próximos à borda do retângulo.




FIGURA 12 – CARACTERÍSTICAS DO FILTRO ATIN  
 FONTE: ADAPTADO DE AXELSSON (2000)

Para a área de estudo A2, usando-se os dados referentes ao primeiro retorno do pulso ALS, com seus valores máximos, gerou-se o MDS. Usando-se os valores mínimos, referentes ao último retorno, gerou-se o MDT. Este MDT apresenta resquícios de algumas árvores, nos locais onde o último retorno não atingiu o solo diretamente. Foram aplicados ao MDT os filtros supracitados, implementados no ALDPAT, e verificou-se que os filtros geraram erros na interpolação dos dados. Comparando-se, por exemplo, os valores de altitude dos pixels no MDT original e nos MDTs após a aplicação dos filtros, constataram-se diferenças superiores a 2 m nas altitudes, já que a filtragem provocou suavização das bordas das feições. Em virtude disso, optou-se por prosseguir os processamentos com o MDT gerado com o último retorno, sem filtragem, apesar da presença de alguns fragmentos de árvores.

Como o MDS apresenta a variação altimétrica das feições em função das altitudes, as alturas dos objetos não são conhecidas. No processo de geração do MDSN as variações altimétricas são normalizadas, sendo todas as alturas reduzidas a um mesmo plano (subtração do relevo) e as alturas dos objetos são acessadas diretamente, sendo representadas as alturas das edificações e das árvores acima da superfície topográfica. O MDSN corresponde à diferença entre o MDS e o MDT. Para os conjuntos de dados referentes às áreas de estudo A1 e A2 foram obtidos os MDSNs usando-se o princípio de matemática de bandas, subtraindo-se o MDT do MDS. A partir dos MDTs foram gerados os mapas de curvas de nível e de declividade, para as duas áreas de estudo.

## B) REGISTRO DOS DADOS ESPECTRAIS E ALTIMÉTRICOS DA ÁREA DE ESTUDO A1

Quando são usadas imagens de diferentes sensores, ou que foram capturadas em datas diferentes, é necessário realizar o registro das imagens antes do uso conjunto dos dados. O registro é um ajuste geométrico para combinar as imagens de uma mesma área, sem necessidade de corrigir estas imagens com

auxílio de dados de campo ou de um mapa. É necessário apenas estabelecer um sistema de referência para que as imagens possam ser corrigidas. Seleciona-se uma imagem como referência e adota-se o seu sistema de coordenadas, em termos de linhas e colunas, para ser o novo referencial. São selecionados pontos de controle identificáveis na imagem de referência e nas demais a serem referenciadas. As outras imagens serão transformadas para este referencial, de modo similar à correção geométrica que é realizada com auxílio de cartas ou dados de campo (coordenadas obtidas com receptores GNSS) (CENTENO, 2009).

Neste estudo, além de serem usados dados multifonte, os mesmos também foram adquiridos em datas diferentes para a área de estudo A1. Para o processamento conjunto de dados multifonte, nos processos de segmentação e classificação, por exemplo, há a necessidade de que os mesmos estejam perfeitamente registrados. Em virtude disso, realizou-se o registro dos dois conjuntos de dados (intensidade e altimétricos - ALS e espectrais - Ikonos).

Os dados altimétricos da área de estudo A1, obtidos com ALS, possuem precisão planimétrica de 0,5 m a 1,0 m (em função da altura de voo na captura dos dados – ver seção 2.2 e quadro 2). A precisão planimétrica da imagem Ikonos não foi determinada, devido à dificuldade de realização do levantamento em campo, por questões logísticas. Em função disso, optou-se por usar a imagem de intensidade como referência e, a partir desta, as quatro bandas da imagem Ikonos foram registradas. Usou-se a imagem de intensidade como referência, pois os dados altimétricos são obtidos com sistema inercial e de posicionamento GNSS acoplados ao sistema de envio/recepção do sinal LASER, o que proporciona maior precisão no posicionamento planimétrico do que as imagens de satélite.

Para a realização do registro, usou-se um recorte da cena Ikonos, compatível com a área abrangida pelos dados oriundos da varredura com ALS. Em virtude de grande parte da área selecionada se encontrar em ambiente rural, não foi possível distribuir homogeneamente os pontos por toda a cena, tendo havido concentração em alguns locais, como no caso da área urbanizada, na parte superior

da imagem. A distribuição se deu em virtude da disponibilidade de feições homólogas bem definidas em ambas as imagens e do controle do erro do registro (estipulado, a priori, para ser inferior a dois pixels). Os pixels foram reamostrados pelo método do vizinho mais próximo, visando a menor interferência possível nos valores digitais. Foram usados dez pontos de controle e doze pontos de verificação (ver apêndice).

### C) GERAÇÃO DA IMAGEM DE ÍNDICE DE VEGETAÇÃO:

O NDVI é obtido a partir das bandas espectrais relativas aos comprimentos de onda do infravermelho próximo (NIR) e do vermelho (bandas 4 e 3 da imagem IKONOS, respectivamente), por meio da expressão:

$$\text{NDVI} = (B4 - B3) / (B4 + B3) \quad (1)$$

Ele permite melhorar a discriminação das áreas vegetadas e não vegetadas. O NDVI varia de -1 a +1 e, quanto maior esse valor, maior a presença de vegetação. O procedimento de geração da imagem NDVI foi realizado sobre a imagem Ikonos, usando-se o princípio de matemática de bandas.

A ortofoto relativa à área de estudo A2 não apresenta a banda do infravermelho próximo, o que não permite a geração do NDVI. Entretanto, percebe-se um contraste entre as áreas de solo na banda do vermelho (mais escuro) e na imagem de intensidade (mais claro) (figura 13).



FIGURA 13 – IMAGEM DA BANDA DO VERMELHO E IMAGEM DE INTENSIDADE ALS  
FONTE: A AUTORA (2015)



Observando-se as curvas típicas da reflectância espectral (figura 14), pode-se perceber que a resposta do solo na faixa do infravermelho próximo (em azul na figura) está em torno de 40%, enquanto que na faixa do vermelho (em vermelho na figura) está abaixo de 30%, o que explica a diferença observada nas duas imagens.




FIGURA 14 - CURVAS TÍPICAS DA REFLECTÂNCIA ESPECTRAL DA ÁGUA, SOLO E VEGETAÇÃO

FONTE: ADAPTADO DE LILLESAND E KIEFER, 2008

Em função disso, foi desenvolvido um índice de contraste com base na imagem de intensidade do ALS (ICBI) e na banda relativa ao comprimento de onda do vermelho, para evidenciar o solo:

$$ICBI_{red} = (Red - Intensidade) / (Red + Intensidade) \quad (2)$$

Esse índice, aqui proposto, apresenta-se como uma alternativa para os casos em que não se dispõe da banda NIR, mas se dispõe da imagem de intensidade. Ao contrário do NDVI, ele destaca o solo e não a vegetação. Há, obviamente, a necessidade de que os dados espectrais e altimétricos tenham sido adquiridos ao mesmo tempo e, portanto, estejam georreferenciados e correspondam

a uma mesma data.

#### 4.3.2 Segmentação - geração de objetos-imagem

A segmentação é o processo de divisão de uma imagem em grupos de pixels que são espectralmente similares e espacialmente adjacentes, formando regiões (ou objetos-imagem) por meio da minimização da variabilidade interna do objeto, se comparada com a variabilidade entre os objetos (DESCLÉE, BOGAERT e DEFOURNY, 2006). As regiões de mínima heterogeneidade devem ser encontradas.

A heterogeneidade pode se referir a atributos primários dos objetos-imagem, tais como desvio padrão ou tons de cinza, forma do objeto, textura, ou sobre atributos de ordem mais elevada, tais como a classe atribuída aos objetos-imagem. Comumente, os métodos de segmentação usam somente os atributos primários, sem uma relação direta com objetos do mundo real (BENZ *et al.*, 2004).

A quantidade de objetos-imagem resultantes da segmentação depende do nível de abstração ou de detalhamento desejado. Portanto, o nível de subdivisão depende do problema a ser resolvido, ou seja, a segmentação é interrompida quando os objetos de interesse tiverem sido isolados. A segmentação não envolve a classificação de cada objeto-imagem. O segmentador apenas subdivide uma imagem, mas não reconhece os objetos individuais ou as relações com os demais (PRATT, 2007). A finalidade, posterior à segmentação, é associar os objetos-imagem a uma determinada feição ou classe do terreno, usando um método de classificação. A figura 15 ilustra uma cena (a) e sua respectiva segmentação (b).

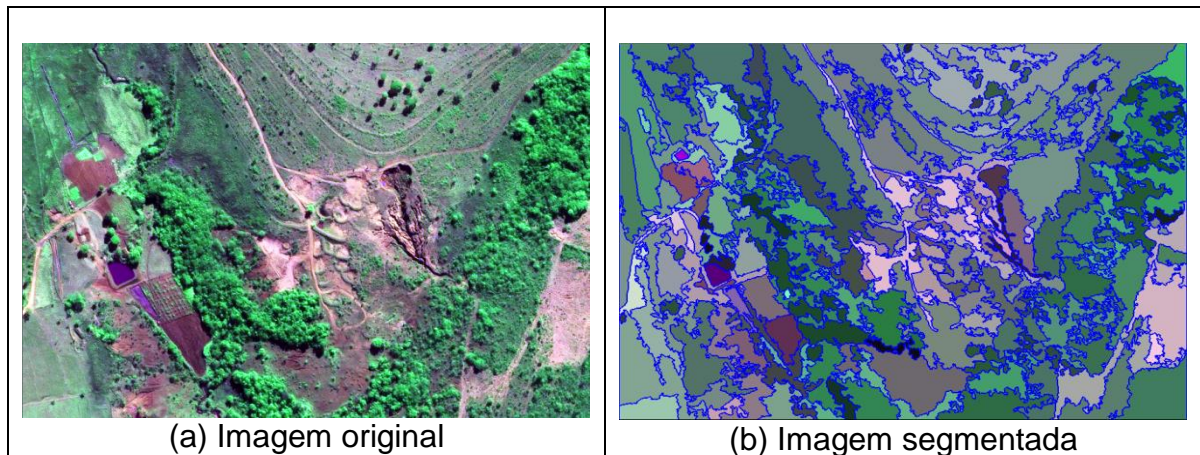


FIGURA 15 – SEGMENTAÇÃO DE IMAGEM  
FONTE: A AUTORA (2015)

Dependendo do tipo de imagem e do objetivo, diferentes métodos de segmentação podem ser aplicados, sendo que não existe um modelo formal para a segmentação. O processo é essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagem, com limiares definidos em função da complexidade dos alvos investigados (ANTUNES, 2003).

A segmentação pode ocorrer em modo supervisionado, quando a imagem é segmentada com base num conhecimento a priori que se tem sobre as classes a serem detectadas, e em modo não supervisionado, quando os objetos-imagem são formados com base nos valores de outras regiões da mesma imagem, ou seja, o algoritmo não supervisionado busca regiões homogêneas dentro da imagem.

Pode, ainda, ser considerada global ou local. Na segmentação global não se considera a informação de pixels vizinhos na divisão da imagem, analisando-se a variação dos valores digitais presentes em toda a imagem e buscando-se formar grupos, partindo da hipótese de que os objetos na imagem aparecem de forma uniforme em termos de cor. São exemplos as técnicas de limiarização (*thresholding*) e de agrupamento (*clustering*). Na segmentação local, os pixels vizinhos são analisados, como é o caso dos métodos baseados em similaridade ou descontinuidade.

Sonka, Hlavac e Boyle (2008) apresentam outro possível agrupamento das técnicas: por limiarização (*thresholding*), baseado em bordas (*edge-based*) e

baseado em regiões (*region-based*). Os métodos baseados em regiões seguem três abordagens básicas: fusão de regiões (*region merging*), divisão de regiões (*region splitting*) e divisão e fusão de regiões (*split-and-merge*).

As técnicas de segmentação são, geralmente, baseadas em análise de descontinuidade ou similaridade de valores digitais. Em se tratando de descontinuidade, o objetivo é particionar a imagem em função de mudanças bruscas nos valores digitais. Este tipo de segmentação é utilizado quando se deseja detectar pontos, linhas e bordas isolados. No caso de análise de similaridade, os pixels adjacentes com propriedades similares são agrupados para formar regiões uniformes. Exemplos deste princípio são as técnicas de crescimento de regiões e divisão e fusão de regiões (GONZALES e WOODS, 2008).

Quanto ao crescimento de regiões, esse é um procedimento que agrupa pixels ou sub-regiões em regiões maiores, sendo que somente pixels adjacentes, contíguos na imagem, podem ser agrupados. A abordagem mais simples é a agregação de pixels, que começa com um conjunto de pontos denominados “semente” e, a partir deles, as regiões crescem anexando a cada ponto semente aqueles pixels que possuam propriedades similares, como valor digital, textura ou cor. O processo é iterativo e termina quando a região não pode crescer mais, com base em parâmetros associados a um limiar pré-estabelecido.

No que tange à segmentação multirresolução, ela baseia-se no conceito de que, ao analisar as imagens de sensoriamento remoto, a visão humana tende a generalizar a imagem dentro de áreas homogêneas, intuitivamente. Sequencialmente, essas áreas são analisadas mais minuciosamente e surgem áreas internas a essas, caracterizando mais detalhadamente as cenas (BLASCHKE e STROBL, 2001). Essa subdivisão resulta em objetos significativos da superfície terrestre e dependentes da escala de análise. Forman (1995) fez uma analogia da percepção dos elementos sobre uma imagem, com uma pessoa que desce ao solo com um balão de forma gradual. Usando essa metáfora, ele ressalta que a percepção humana abruptamente começa a descobrir padrões e mosaicos. Muitos

mosaicos são quase estáveis ou persistentes durante algum tempo, separados por mudanças rápidas que representam os domínios da escala. Cada domínio exhibe certos padrões espaciais, os quais, por sua vez, são produzidos por um mecanismo causal ou grupo de processos. Essa analogia permite afirmar que a visão humana identifica mosaicos de objetos quando analisando imagens de sensores remotos, sendo estas variáveis de acordo com a escala de visualização (ou altura do voo do balão, na metáfora) (BLASCHKE e STROBL, 2001).

Embora certa escala possa ser presumida em função da resolução espacial, os objetos de interesse desejados frequentemente têm sua própria escala inerente. A escala determina a ocorrência ou não ocorrência de certas classes de objetos. Além disso, o mesmo tipo de objetos ocorre de forma diferente em diferentes escalas. Isso implica que os objetos de interesse determinam diretamente uma escala particular de interesse. A resolução espacial de uma imagem refere-se às dimensões da área média que um pixel cobre no terreno, enquanto que a escala descreve a magnitude ou nível de agregação (e abstração) no qual certo fenômeno pode ser descrito. Portanto, analisar uma imagem em níveis diferentes de escala, ao invés de usar imagens com diferentes resoluções, é mais adequado para a identificação de feições e a compreensão das relações dentro de uma imagem. Entre as escalas há uma dependência hierárquica e, por isso, é necessário representar o conteúdo da imagem em muitas escalas simultaneamente, explorando as dependências de escala hierárquica entre os objetos-imagem resultantes (BENZ *et al.*, 2004; BAATZ *et al.*, 2001).

O processo de segmentação gera objetos-imagem que não serão significativos em todas as escalas, tampouco para qualquer aplicação ou análise. No processo de classificação, os objetos-imagem serão identificados de forma mais precisa se forem analisados em tamanhos diferentes. Isso conduz à necessidade da realização de uma segmentação multiescala, ou multirresolução.

Baseados na natureza fractal das imagens de sensoriamento remoto, Baatz e Schäpe (1999) introduziram a FNEA (*Fractal Net Evolution Approach*),

procedimento também denominado de segmentação multirresolução. A técnica consiste em extrair os objetos e, posteriormente, classificá-los por meio da lógica fuzzy.

A segmentação multirresolução é uma técnica ascendente de crescimento de regiões, começando pelos objetos com o tamanho do pixel. Em vários passos subsequentes, os objetos menores são unidos em objetos maiores. Durante todo o processo de agrupamento em pares, o procedimento de otimização subjacente minimiza a heterogeneidade ponderada " $n h$ " dos objetos-imagem resultantes, sendo  $n$  o tamanho de um objeto e  $h$  um parâmetro de heterogeneidade. Em cada passo, o par de objetos-imagem adjacentes é unido, desde que resulte no menor crescimento da heterogeneidade estipulada. Se o menor crescimento excede o limiar definido pelo parâmetro de escala, o processo é interrompido. Dessa forma, a segmentação multirresolução é um procedimento de otimização local, que simula o crescimento simultâneo de objetos-imagem sobre a cena, em cada passo, para alcançar objetos-imagem adjacentes de tamanho similar e, conseqüentemente, de escala comparável (BENZ *et. al.*, 2004).

No início do processo, cada pixel da imagem é considerado como sendo um objeto-imagem e, em vários passos subsequentes, os objetos-imagem são unidos em pares, formando objetos maiores, desde que um critério de homogeneidade não seja excedido localmente. Este critério de homogeneidade (ou de heterogeneidade minimizada) é definido como uma combinação de homogeneidade espectral e homogeneidade de forma. O cálculo da homogeneidade é influenciado pelo usuário, por meio da modificação do parâmetro de escala. Valores grandes para o parâmetro de escala resultam em objetos-imagem maiores, enquanto que valores pequenos resultam em objetos-imagem menores. A cada passo, os dois objetos-imagem que geram um novo objeto-imagem mais uniforme, em termos espectrais e espaciais, são fundidos (cada objeto-imagem e seus vizinhos são analisados). O par de vizinhos que mais se assemelham é escolhido para a fusão. Caso exista mais de um vizinho semelhante, é escolhido o que possui menor fator de heterogeneidade. O

processo continua até que um número de iterações seja atingido ou não existam mais fusões (TRIMBLE, 2012).

Os parâmetros de escala (PE) e de heterogeneidade (PH) devem ser definidos pelo usuário. O PE é um termo abstrato e controla o tamanho de cada objeto-imagem, de modo que este corresponda a uma Unidade Mínima de Mapeamento (MMU - *Minimal Mapping Unit*). O PE é determinado pelas características de escala dos objetos de estudo através de repetidos experimentos. Quanto maior o parâmetro de escala, mais objetos-imagem podem ser fundidos e mais eles crescem. O parâmetro de escala é o critério de parada para a otimização do processo. Antes da fusão de dois objetos-imagem adjacentes, o aumento resultante da heterogeneidade “f” é calculado. Se esse aumento do resultado excede um limiar “t” antigo, determinado pelo parâmetro de escala ( $t = PE$ ), a segmentação é interrompida.

O PH é baseado em três critérios: cor (heterogeneidade espectral), suavidade e compacidade (heterogeneidade de forma) (WANG *et al.*, 2014). Na maioria dos casos, a cor é o critério mais importante para gerar objetos-imagem significativos. Entretanto, a forma pode melhorar a qualidade da extração dos objetos, por exemplo, na segmentação de dados fortemente texturizados, como é o caso dos dados de radar. A figura 16 ilustra os parâmetros a serem definidos preliminarmente ao processo da segmentação. Cada componente do par de critérios (cor e forma; suavidade e compacidade) deve ser ponderado percentualmente (equalizado ao valor 1), ou seja, atribuindo-se peso 0,6 para a cor, proporcionalmente tem-se peso 0,4 para a forma. Neste caso, não se deve atribuir à forma um valor maior que 0,9, pois, dessa forma, os objetos-imagem resultantes não estarão relacionados com a informação espectral.




FIGURA 16 – PARÂMETROS DA SEGMENTAÇÃO MULTIRRESOLUÇÃO  
 FONTE: ADAPTADO DE TRIMBLE (2012)

- Cálculo do Critério de Heterogeneidade (BAATZ *et al.*, 2001):

**1) Heterogeneidade espectral ( $h_{\text{espectral}}$ ):** é descrita pela variância ou desvio padrão dos pixels (do objeto-imagem) em cada banda. É adotado o somatório dos desvios padrão ( $\sigma_c$ ) dos valores espectrais em cada banda ( $c$ ) ponderados com o peso ( $w_c$ ) atribuído para cada banda:

$$h_{\text{espectral}} = \sum_c w_c \cdot \sigma_c \quad (3)$$

**2) Compacidade:** representa o quão compactos estão os pixels de um determinado objeto-imagem. O critério de compacidade deve ser usado quando um contraste espectral fraco separa os objetos que são muito compactos dos que não são compactos. O peso para o critério de compacidade assume valores no intervalo de 0 a 1. O coeficiente de compacidade ( $h_{\text{compac}}$ ) é calculado por:

$$h_{\text{compac}} = L/\sqrt{n} \quad (4)$$

sendo  $L$  o comprimento (perímetro) da borda e  $n$  o número de pixels formadores do objeto-imagem.

**3) Suavidade:** representa o grau de irregularidade do contorno de um objeto-imagem. O coeficiente de suavidade ( $h_{\text{suav}}$ ) é obtido pela comparação do perímetro do objeto-imagem ( $L$ ) com o perímetro do menor retângulo envolvente ( $b$ ):



$$h_{suav} = \frac{L}{b} \quad (5)$$

**4) Heterogeneidade de forma ( $h_{forma}$ ):** é função dos coeficientes de compacidade e suavidade:

$$h_{forma} = w_{compac} \cdot h_{compac} + (1 - w_{compac}) \cdot h_{suav} \quad (6)$$

5) Custo de fusão de dois objetos (f):

$$f = w \cdot h_{espectral} + (1 - w) \cdot h_{forma} \quad (7)$$

sendo:

$w$  = peso atribuído à cor ( $0 \leq w \leq 1$ )

$h_{espectral}$  = heterogeneidade espectral

$h_{forma}$  = heterogeneidade espacial (da forma)

Haverá fusão entre os objetos-imagem se o custo de fusão for menor que um critério definido como escala. A mudança na heterogeneidade espectral, causada pela fusão ( $h_{espectral-fusão}$ ), é avaliada pelo cálculo da diferença entre a situação antes ( $obj1$  e  $obj2$ ) e após a fusão:

$$h_{espectral-fusão} = \sum_c w_c (n_{fusão} \cdot \sigma_c^{fusão} - (n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2})) \quad (8)$$

sendo:

$w_c$  = peso atribuído a cada banda  $c$ ;

$n_{fusão}$  = número de pixels do objeto-imagem após a fusão;

$n_{obj1}$  = número de pixels do objeto- imagem 1, antes da fusão;

$n_{obj2}$  = número de pixels do objeto- imagem 2, antes da fusão;

$\sigma_c^{fusão}$  = desvio padrão dos valores espectrais dentro do objeto-imagem fusionado, em cada banda  $c$ ;

$\sigma_c^{obj1}$  = desvio padrão dos valores espectrais dentro do objeto-imagem 1, em cada banda c, e

$\sigma_c^{obj2}$  = desvio padrão dos valores espectrais dentro do objeto-imagem 2, em cada banda c.

A mudança na heterogeneidade espacial, causada pela fusão, é avaliada pelo cálculo da diferença entre a situação antes (obj1 e obj2) e após a fusão:

$$h_{suav-fusão} = n_{fusão} * \frac{L_{fusão}}{b_{fusão}} - (n_{obj1} * \frac{L_{obj1}}{b_{obj1}} + n_{obj2} * \frac{L_{obj2}}{b_{obj2}}) \quad (9)$$

$$h_{compac-fusão} = n_{fusão} * \frac{L_{fusão}}{\sqrt{n_{fusão}}} - (n_{obj1} * \frac{L_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} * \frac{L_{obj2}}{\sqrt{n_{obj2}}}) \quad (10)$$

sendo:

$n_{fusão}$  = número de pixels do objeto-imagem após a fusão;

$L_{fusão}$  = perímetro do objeto-imagem após a fusão;

$b_{fusão}$  = perímetro do retângulo envolvente do objeto-imagem após a fusão;

$n_{obj1}$  = número de pixels do objeto-imagem 1, antes da fusão;

$n_{obj2}$  = número de pixels do objeto-imagem 2, antes da fusão;

$L_{obj1}$  = perímetro do objeto-imagem 1;

$L_{obj2}$  = perímetro do objeto-imagem 2;

$b_{obj1}$  = perímetro do retângulo envolvente do objeto-imagem 1, e

$b_{obj2}$  = perímetro do retângulo envolvente do objeto-imagem 2.

A segmentação é feita de forma fina e grosseira, progressivamente, originando escalas de segmentação. O procedimento é similar ao crescimento de regiões que agrupa pixels ou sub-regiões em regiões maiores. Não existe uma escala ideal para os objetos-imagem, sendo dependente da resolução dos dados e dos objetos de interesse. Cada escala gerará um nível de agrupamento de objetos-imagem (BLASCHKE *et al.*, 2000; BLASCHKE e HAY, 2001). A figura 17 mostra os

objetos-imagem obtidos pela segmentação de uma cena em diferentes escalas.

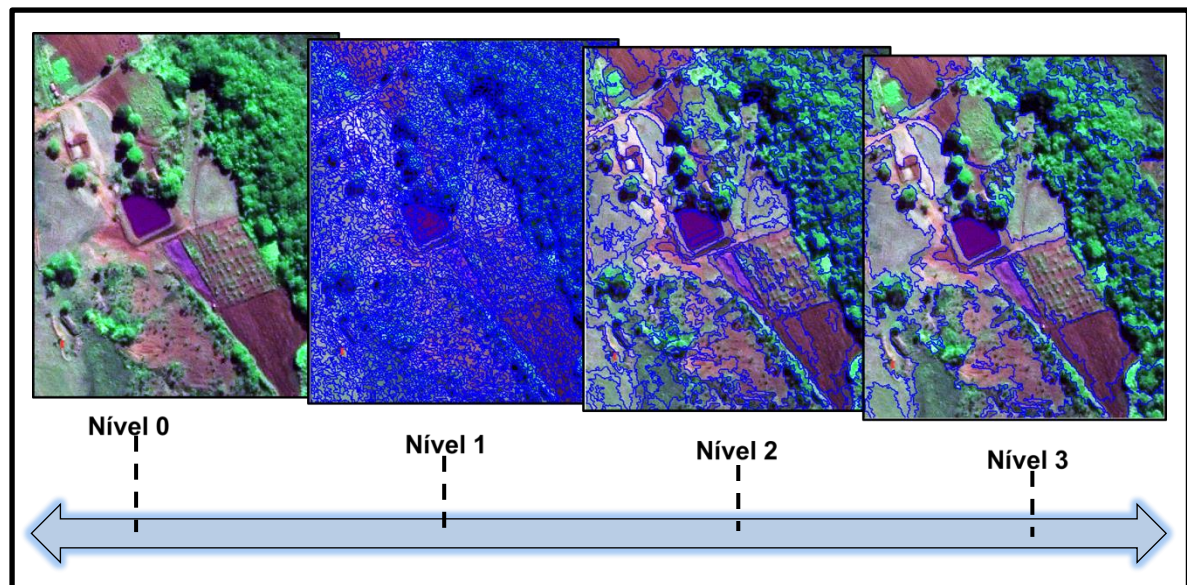


FIGURA 17 – OBJETOS-IMAGEM RESULTANTES DA SEGMENTAÇÃO EM DIFERENTES ESCALAS

FONTE: A AUTORA (2015)

Como o nível que apresenta os pixels e o nível que apresenta a imagem inteira sempre existem, cada segmentação de um novo nível é uma construção entre um nível mais baixo e um mais alto, ou seja, intermediário entre a escala mais fina e a mais grosseira. Para garantir uma hierarquia precisa sobre a forma espacial de todos os objetos-imagem, os procedimentos de segmentação seguem duas regras (BENZ *et. al.*, 2004):

- as bordas dos objetos-imagem devem seguir as bordas dos objetos-imagem do nível mais baixo, e
- a segmentação é controlada pela borda do objeto-imagem no nível acima.

A conexão dos níveis ocorre na forma de uma rede hierárquica, a qual representa a informação da imagem em diferentes resoluções espaciais, simultaneamente. Os subobjetos (gerados nas escalas menores) estão contidos nos superobjetos (gerados em escalas maiores, a partir da junção dos subobjetos). A rede hierárquica é definida topologicamente, ou seja, a borda de um superobjeto é

consistente com a borda de seus subobjetos. A área representada por um objeto-imagem específico é definida pelo somatório da área de seus subobjetos. Na rede hierárquica, cada objeto-imagem conhece seus vizinhos adjacentes, seus subobjetos e seus superobjetos, o que permite o uso de informação contextual na classificação por meio de operações de vizinhança entre os objetos-imagem em rede (BAATZ; SCHÄPE, 1999). A figura 18 ilustra a rede hierárquica dos objetos-imagem e suas relações topológicas.

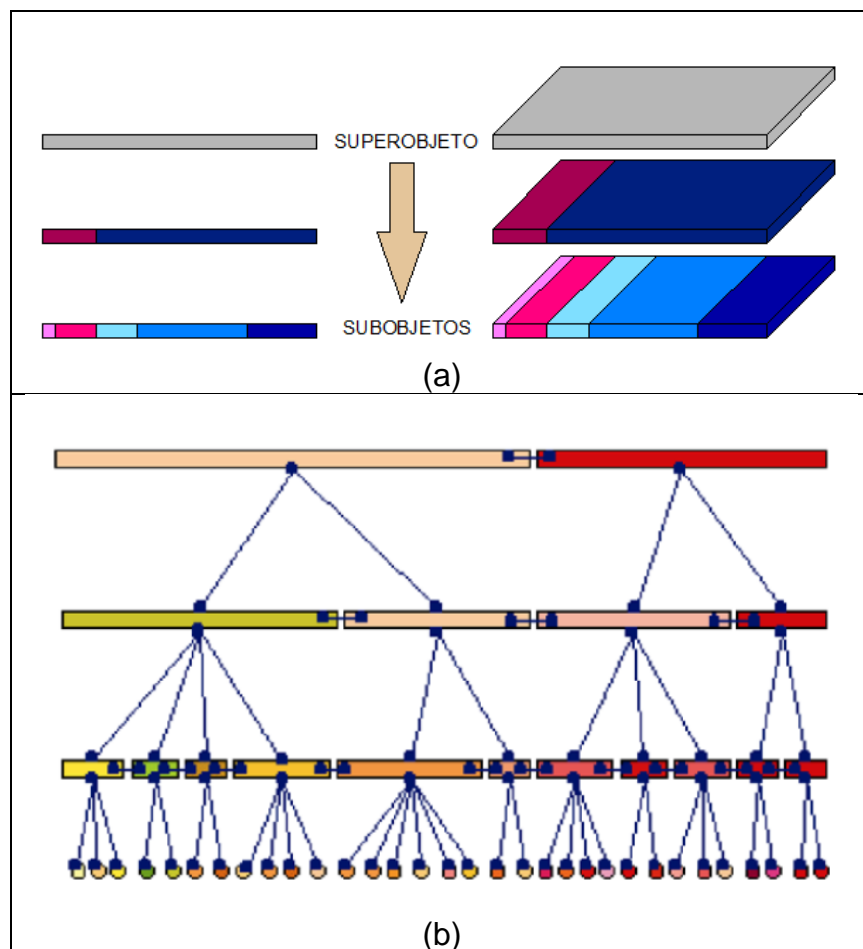


FIGURA 18 – REDE HIERÁRQUICA DE OBJETOS-IMAGEM E SUAS RELAÇÕES TOPOLÓGICAS  
 FONTE: A) A AUTORA (2015); B) BENZ ET AL. (2004)

Neste estudo, como as feições constituintes das voçorocas possuem tamanhos diferentes, a geração de objetos foi realizada, para as duas áreas de estudo, usando-se o método FNEA, com auxílio do algoritmo de segmentação multirresolução.

Os objetos-primitivos foram gerados com fator de escala igual a 5 e os superobjetos (objetos gerados em níveis acima) foram gerados com variações pequenas do fator de escala (de 5 em 5) entre níveis diferentes. Isso se deu em função de que, nos casos em que há grande heterogeneidade dos objetos presentes na cena numa pequena área considerada (como no caso da área de estudo A2, com a presença de várias árvores isoladas), a segmentação com fatores de escala variando abruptamente, gerará a fusão dos objetos menores, suprimindo-os em função de objetos maiores vizinhos. Quando o processo é realizado com variação pequena do fator de escala, os objetos menores, quando diferem muito de sua vizinhança, são preservados. Obviamente, esta etapa é dependente da resolução espacial dos dados. Para o caso de sistemas de voçorocas, a geração gradual dos objetos preserva as feições menores, como os dígitos.

Para a escolha dos dados a serem usados na segmentação dos objetos do tipo voçoroca, considerou-se o fato de que há diferenças entre as bordas dos objetos em dados ALS e em imagens de satélite ou ortofoto. Uma possível explicação para esta diferença, principalmente em relação à voçoroca, é a ocorrência de áreas de oclusão.

Na figura 19 é possível perceber que, se a coleta dos dados altimétricos não for realizada verticalmente ao objeto de interesse, não será possível obter-se o contorno real do mesmo. No caso da voçoroca, se houve o retorno do pulso evidenciado em linha mais grossa na figura, no processo de geração do MDS esses pontos serão interpolados, como se formassem uma vertente única. Além disso, em um MDT, objetos de vegetação rasteira, solo, corpos d'água, asfalto (estradas), podem estar todos na mesma altitude e, usando-se os dados altimétricos para a segmentação, eles seriam unidos em um único objeto. A resposta espectral é que permite a diferenciação entre as diferentes coberturas terrestres. Em virtude disso, e após a realização de vários testes com combinações de dados, como não há coincidência das bordas, principalmente para a área de estudo A1, optou-se por realizar a segmentação usando-se apenas as informações espectrais, que são

características intrínsecas dos objetos. Os dados altimétricos foram usados como atributos auxiliares na discriminação entre classes.




FIGURA 19 – ÁREAS DE OCLUSÃO NOS DADOS ALS  
FONTE: A AUTORA (2015)

Devido às formas irregulares, distintas e sem um padrão de repetição, atribuiu-se maior peso à variável cor, do que à de forma, no processo de segmentação. Como a forma das feições é bastante variável, foram atribuídos pesos iguais às variáveis de compacidade e suavidade. Todos os parâmetros de segmentação foram selecionados de forma empírica.

As segmentações obtidas com os diferentes fatores de escala foram analisadas, visando identificar em que nível de segmentação as feições da voçoroca (cabeceira, dígitos e bordas), bem como as feições das demais classes, foram delineadas pelos objetos.

Como o processamento de cada área de estudo se deu de forma independente, em virtude da diversidade de dados e características de cada cena, os critérios de seleção dos parâmetros ótimos para a segmentação também serão explanados de forma independente, a seguir.

#### - ÁREA DE ESTUDO A1:

Como dados de entrada para a segmentação, foram utilizadas as quatro

bandas da imagem IKONOS e a imagem de intensidade do ALS. Variou-se o fator de escala (FE) de 5 a 100 (com intervalos múltiplos de 5, ex: 5-10-15-20...), e FE=125 e FE=150. Como parâmetros de entrada para o algoritmo, atribuiu-se maior peso à cor (0,9) do que à forma (0,1), pois, após realização de testes, verificou-se que a variação desses parâmetros não alterou as segmentações. Quanto ao parâmetro de heterogeneidade de forma, usou-se compacidade = 0,5 e suavidade = 0,5. Os produtos altimétricos derivados do ALS (MDS, MDSN, MDT, mapa de declividade e de curvas de nível) e o NDVI foram descartados da segmentação, pois apresentaram respostas muito diferentes das obtidas nas bandas espectrais e, por isso, não haveria coincidência dos objetos gerados em função da resposta espectral e dos produtos derivados. Além disso, como os dados altimétricos e espectrais não foram obtidos em conjunto, e devido à amostragem dos pontos e áreas de oclusão, há uma pequena variação nas bordas dos objetos gerados a partir dos dados ALS, quando comparados à imagem Ikonos.

#### - ÁREA DE ESTUDO A2:

Como dados de entrada para a segmentação foram utilizados: as três bandas da ortofoto e a imagem de intensidade do ALS. A geração dos objetos-imagem primitivos foi realizada com o fator de escala (FE) igual 5. Variou-se o FE de 5 a 100 (com intervalos múltiplos de 5, ex: 5-10-15-20...). Como parâmetros de entrada para o algoritmo, atribuiu-se maior peso à cor (0,9) do que à forma (0,1). Quanto ao parâmetro de heterogeneidade de forma, usou-se compacidade = 0,5 e suavidade = 0,5.

#### 4.3.3 Planejamento da classificação

O planejamento da classificação se deu em quatro etapas: definição da rede semântica, identificação das chaves de interpretação, definição da rede hierárquica e seleção de atributos. Primeiramente, foram identificadas, para cada área de

estudo, as classes susceptíveis de serem discriminadas pelo procedimento de classificação, definindo-se, assim, a rede semântica. Para a área de estudo A1, a definição ocorreu em função do reconhecimento de campo no local e da análise dos dados. Para a área de estudo A2, em virtude da impossibilidade do reconhecimento no local, a rede semântica foi definida apenas com base na observação dos dados disponíveis. Foram então analisadas as chaves de interpretação, relativas às características de cor, forma, tamanho, textura e variação de altura dos elementos representativos de cada classe.

O uso de objetos segmentados na forma multiescala permite que os mesmos sejam usados para classificação em diferentes níveis, de forma hierárquica. Dessa forma, é possível classificar os objetos de uma determinada classe no nível em que os mesmos estão definidos da forma mais próxima da realidade. Em virtude disso, é necessário elaborar, além da rede semântica, a rede hierárquica, na qual estão explícitas as informações sobre nível de segmentação e dependências com superclasses e subclasses. A rede hierárquica foi usada na classificação hierárquica. Para a classificação por árvore de decisão, apenas a rede semântica é necessária, pois esta etapa é realizada em apenas um nível de segmentação.

Além das chaves de interpretação, foram analisados os atributos disponíveis no programa eCognition, relativos às informações espectrais, altimétricas, geométricas, de textura e de contexto.

Os objetos-imagem possuem características (que também podem ser denominadas como descritores ou atributos) espectrais, geométricas, hierárquicas, de textura, de posição e temáticas (relativas à classe à qual pertencem os objetos) (TRIMBLE, 2012). A figura 20 ilustra algumas das características disponíveis no programa eCognition.



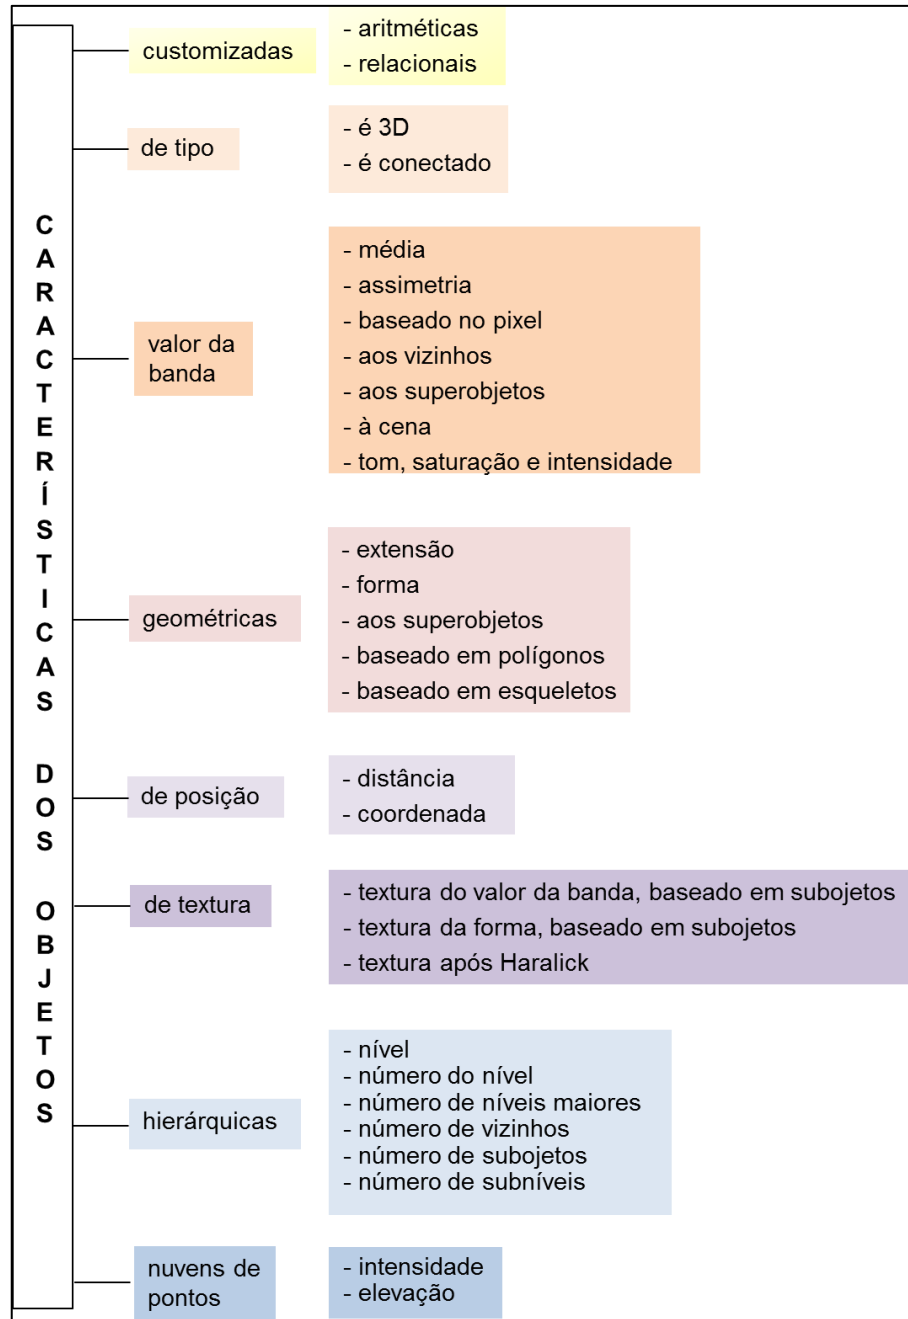


FIGURA 20 – CARACTERÍSTICAS DOS OBJETOS-IMAGEM  
 FONTE: A AUTORA (2015)

As características espectrais estão relacionadas aos valores dos pixels e objetos em cada banda das imagens utilizadas. A figura 21 ilustra as características possíveis de serem derivadas a partir da informação do nível digital de cada pixel e de cada objeto.

E S P E C T R A I S	VALOR DA BANDA	<b>Média:</b>	<ul style="list-style-type: none"><li>- brilho</li><li>- máxima diferença</li></ul>
		<b>Assimetria</b>	
		<b>Baseado no pixel:</b>	<ul style="list-style-type: none"><li>- razão</li><li>- mínimo valor do pixel</li><li>- máximo valor do pixel</li><li>- média da borda interna</li><li>- média da borda externa</li><li>- contraste da borda</li><li>- contraste para pixels vizinhos</li><li>- contraste de borda dos pixels vizinhos</li><li>- desvio-padrão para pixels vizinhos</li><li>- média circular</li><li>- desvio-padrão circular</li><li>- desvio-padrão/média circular</li></ul>
		<b>Aos vizinhos:</b>	<ul style="list-style-type: none"><li>- diferença média aos vizinhos</li><li>- dif. média absoluta aos vizinhos</li><li>- dif. média aos vizinhos escuros</li><li>- dif. média aos vizinhos claros</li><li>- número de objetos claros</li><li>- número de objetos escuros</li><li>- borda relativa a objetos claros</li></ul>
		<b>Aos superobjetos:</b>	<ul style="list-style-type: none"><li>- diferença média ao superobjeto</li><li>- razão ao superobjeto</li><li>- desvio-padrão da dif. ao superobjeto</li><li>- desvio-padrão da razão ao superobjeto</li></ul>
		<b>À cena:</b>	<ul style="list-style-type: none"><li>- diferença média para a cena</li><li>- razão para a cena</li></ul>
		<b>Tom, saturação e intensidade</b> ( <i>Hue, Saturation, Intensity</i> )	

FIGURA 21 – CARACTERÍSTICAS ESPECTRAIS DOS OBJETOS-IMAGEM  
 FONTE: A AUTORA (2015)

Quando o pixel é usado como unidade de informação, o descritor espectral disponível é o valor de intensidade do pixel, em cada banda (ou camada L). Quando os objetos-imagem são usados como unidade de informação, é necessário usar o valor médio de intensidade de todos os pixels que compõem o objeto.

- **Valor médio da banda ( $C_L$ ):** O valor médio pode ser obtido por (BAATZ *et al.*, 2001):

$$C_L = \frac{1}{n} * \sum_{i=1}^n C_{Li} \quad (11)$$

sendo:

$C_L$  = valor médio calculado;

$n$  = número de pixels que formam o objeto, e

$C_{Li}$  = valor médio da intensidade do pixel “i” na banda “L”

- **Brilho ( $\bar{c}(v)$ ):** Outro valor médio que pode ser considerado é o do brilho de todos os pixels pertencentes ao objeto, para todas as bandas (k) que se deseje considerar no cálculo, dado por (BAATZ *et al.*, 2001):

$$\bar{c}(v) = \frac{1}{w^B} * \sum_{k=1}^K w_k^B * \bar{c}_k(v) \quad (12)$$

sendo:

$\bar{c}(v)$  = valor médio do brilho calculado;

$w^B$  = soma dos pesos dos brilhos de todas as bandas “k” usados no cálculo, sendo

$$w^B = \sum_{k=1}^K w_k^B;$$

$K$  = número de bandas “k” usados no cálculo;

$w_k^B$  = peso do brilho “B” da banda “k”, com  $w_k^B = [0, 1]$ ;

$\bar{c}_k(v)$  = intensidade média do objeto “v” na banda “k”;

Intervalo de valores:  $[c_k^{\min}, c_k^{\max}]$ , sendo  $c_k^{\min}$  = valor de intensidade mais escuro possível da banda “k” e  $c_k^{\max}$  = valor de intensidade mais claro possível da banda “k”.

Quando todas as bandas espectrais disponíveis da imagem são utilizadas como fonte de informação, o peso é igual a 1 para todas. Caso uma banda não contenha informação relevante para a discriminação de uma determinada feição, pode-se atribuir um peso (w) igual a zero à mesma. No programa eCognition, o peso pode ainda variar de 1 a 0, evidenciando-se a importância de cada banda no

processo de identificação das feições.

- **Máxima Diferença (maxdif):** O valor médio pode ser usado ainda para obter-se o descritor da Máxima Diferença, o qual é dado por (BAATZ *et al.*, 2001):

$$\text{maxdif} = \frac{[\max_{i,j \in K_B} |\bar{c}_i(v) - \bar{c}_j(v)|]}{\bar{c}(v)} \quad (13)$$

sendo:

$i, j = \text{bandas};$

$\bar{c}(v) = \text{brilho do objeto "v"};$

$\bar{c}_i(v) = \text{intensidade média do objeto "v" na banda "i"};$

$\bar{c}_j(v) = \text{intensidade média do objeto "v" na banda "j", e}$

$K_B = \text{bandas consideradas}$

Intervalo de valores:

$[0, \frac{1}{K_B} c_K^{\max}]$ , sendo  $c_K^{\max}$  o valor de intensidade mais claro possível da banda k

- **Média Circular:** calcula a média de todos os pixels dentro de um anel ao redor do centro de um objeto-imagem. A espessura do anel é definida por dois valores de raio  $R_1$  e  $R_2$ , estimados em função do tamanho dos objetos e da resolução da imagem:

$$(R_1 - 0,5) \leq d(u,v) \leq (R_2 + 0,5) \quad (14)$$

sendo:

$R_1 = \text{raio interno do anel};$

$R_2 = \text{raio externo do anel};$

$d(u,v) = \text{distância entre objetos, e}$

Intervalo de valores:  $[R_1, R_2]$

Dentre as características geométricas, as mais básicas que podem ser citadas, estão relacionadas à extensão e forma dos objetos, conforme ilustrado na figura 22.

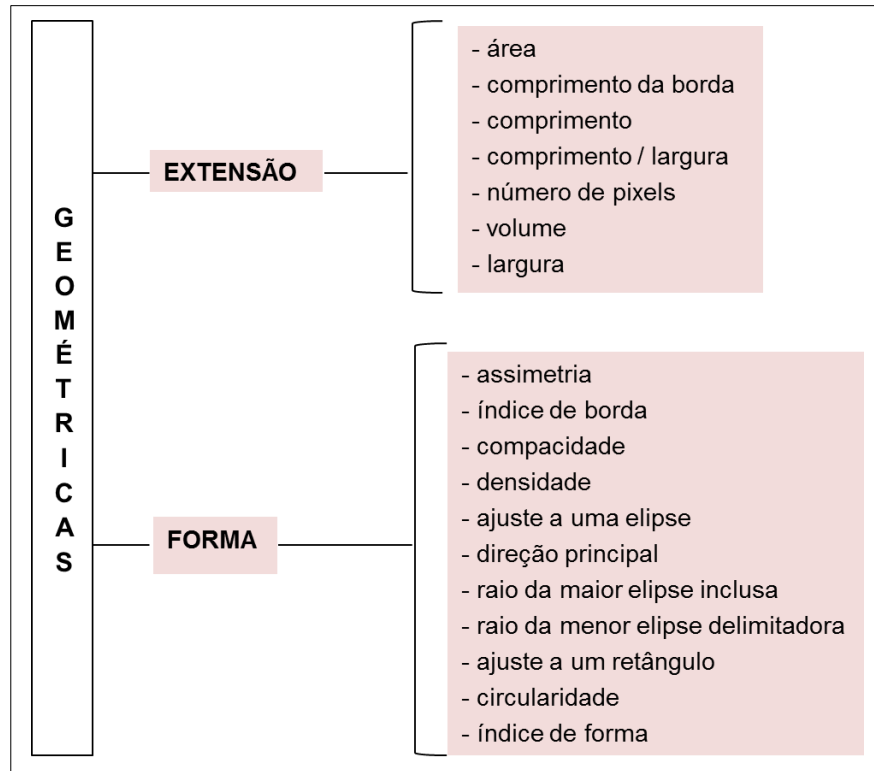


FIGURA 22 – CARACTERÍSTICAS GEOMÉTRICAS DOS OBJETOS-IMAGEM  
 FONTE: A AUTORA (2015)

Muitas das características de forma baseiam-se nas estatísticas da distribuição espacial dos pixels que formam um objeto-imagem, as quais são derivadas a partir da matriz de covariância S:

$$S = \begin{bmatrix} \text{Var}(X) & \text{Cov}(XY) \\ \text{Cov}(XY) & \text{Var}(Y) \end{bmatrix} \quad (15)$$

sendo X as coordenadas x de todos os pixels formadores do objeto-imagem e Y as coordenadas y de todos os pixels formadores do objeto-imagem.

A textura é uma combinação da magnitude e frequência das variações de níveis digitais, em uma determinada área da imagem (objeto-imagem, por exemplo). Está intrinsecamente relacionada à tonalidade, pois sem variação de tonalidade não há variação de textura. É uma característica que não pode ser distinguida visualmente em um pixel singular, mas apenas em um conjunto de pixels (CRÓSTA, 1993).

Haralick, Shanmugam e Dinstein (1973) descreveram uma metodologia de classificação de imagens com base em textura, a partir de características advindas do cálculo de matrizes de coocorrência, que são matrizes que contam o número de vezes em que aparecem determinados valores digitais em uma imagem. Essas características servem como medida para a diferenciação de texturas que não seguem um determinado padrão de repetitividade. A matriz de coocorrência de níveis de cinza (GLCM - *gray level co-occurrence matrix*) é uma matriz que mostra a organização espacial da ocorrência de valores digitais em uma imagem. Em se tratando de análise orientada a objeto, existe uma GLCM diferente para cada objeto. São considerados pares de pixels e estes são avaliados por uma relação espacial fixa que define a distância e a direção que um pixel de referência possui em relação ao pixel vizinho. A variação da direção entre pixels vizinhos é feita em termos angulares ( $\theta$ ) e são considerados quatro direcionamentos:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ . Cada direcionamento dá origem a uma GLCM distinta. Quanto à distância, a mesma pode ser calculada por (HARALICK e SHAPIRO, 1985):

$$d [(k,l),(m,n)] = \max \{ |k-m|, |l-n| \} \quad (16)$$

sendo  $(k,l)$  e  $(m,n)$  as coordenadas linha e coluna de dois pixels vizinhos.

Cada elemento da GLCM corresponde à contagem do número de ocorrências de um dado valor digital para os pares de pixel com uma distância  $d$  e direção  $\theta$ . A matriz resultante é então normalizada e seus valores estão compreendidos no intervalo  $[0; 1]$ . A partir da normalização podem ser calculados os atributos derivados, como contraste, homogeneidade, dissimilaridade, entropia, segundo momento angular, média, desvio-padrão e correlação. A GLCM normalizada é simétrica. Os elementos da diagonal representam pares de pixels sem diferença dos níveis de cinza. As células, que estão a uma célula de distância da diagonal, representam pares de pixels com uma diferença de apenas um valor

digital. Da mesma forma, os valores nas células que estão a dois pixels de distância da diagonal, mostram a quantidade de pixels que têm dois níveis de cinza de diferença e assim por diante. Quanto mais distante da diagonal, maior é a diferença entre os níveis de cinza dos pixels. Somando-se os valores destas diagonais paralelas, tem-se a probabilidade para cada pixel de ser 0, 1, 2, 3, etc, diferente dos seus pixels vizinhos (TRIMBLE, 2012).

Outra abordagem para medir a textura é a utilização de um vetor de diferenças de nível de cinza (GLDV - *Gray-Level Difference Vector*). O GLDV é a soma das diagonais da GLCM e conta a ocorrência de referências para as diferenças absolutas dos pixels vizinhos. É possível, a partir da GLDV, calcular os seguintes atributos: contraste, entropia, segundo momento angular e média.

No eCognition, a GLCM e o GLDV podem ser acessados como “Textura de Haralick”, já que a GLCM e todos os atributos dela decorrentes foram propostos por Haralick e outros autores. Ambos são calculados com base nos pixels de um objeto-imagem e são computados para cada camada de entrada. Para a GLCM e o GLDV é possível escolher para o cálculo de cada atributo (contraste, entropia, etc) as direções 0° (vertical), 45°, 90° (horizontal), 135° ou todas as direções. O cálculo dos atributos de textura com base na GLCM de Haralick independe da resolução radiométrica dos dados da imagem. O intervalo de valores é requantizado para 8 bits antes de avaliar a coocorrência. No entanto, se os dados de 8 bits são utilizados diretamente os resultados serão mais fidedignos. Ao usar dados com mais de 8 bits, a média e o desvio-padrão dos valores são calculados. Assumindo uma distribuição Gaussiana dos valores, um valor maior do que 95% é isolado do intervalo, o qual é subdividido em 255 subintervalos iguais para se obter uma representação de 8 bits. Para cada atributo há uma versão de desempenho otimizado com o sufixo “quick 8/11”. As características são marcadas como “quick 8/11” porque a otimização de desempenho funciona apenas em dados com resolução radiométrica de 8 ou 11 bits (TRIMBLE, 2012).

O atributo GLDV Entropia indica o grau de homogeneidade local na imagem. Os valores são altos se todos os elementos têm valores similares.

Para este estudo, no total, foram analisados 345 atributos. A análise, a priori, se deu de forma qualitativa, observando-se a possibilidade de discriminação das classes para cada atributo analisado. Essa pré-análise se deu para evitar o esforço computacional para a mineração de dados usando os 345 atributos aplicados a toda a imagem, o que resultaria em um grande volume de dados. Os atributos selecionados pela análise qualitativa foram submetidos ao processamento por algoritmos de árvores de decisão (mineração de dados) e selecionados em função de sua relevância na separação entre classes. Além dos atributos indicados pela árvore de decisão, na classificação hierárquica foram inseridos atributos e regras de pertinência fuzzy para melhorar a distinção entre classes.

#### 4.3.4 Classificação por árvores de decisão

Uma árvore de decisão é um classificador expresso como uma partição ou divisão recursiva do espaço de amostras/instâncias/exemplos (MAIMON e ROKACH, 2010). Pode ser usada tanto para procedimentos de classificação como de regressão. Na classificação, permite a categorização de dados usando uma estrutura hierárquica sendo, portanto, um algoritmo para rotulagem / categorização / classificação de padrões desconhecidos, usando uma sequência de decisões (TSO e MATHER, 2009).

Os algoritmos de indução de árvores de decisão correspondem a um método de aprendizado supervisionado, pois possibilitam a extração de conhecimento a partir de exemplos de entrada, na forma de amostras de treinamento. As amostras, para classificação supervisionada, são representadas por um vetor de valores de características, ou atributos, e o rótulo da classe associada.

As árvores de decisão podem ser representadas como um conjunto de regras SE-ENTÃO (*if-then*), ou graficamente. Na representação gráfica, o algoritmo



assume a forma de uma árvore invertida, na qual os diferentes níveis de classificação são representados por níveis separados de hierarquia (TSO e MATHER, 2009). A árvore enraizada é conduzida por um nó chamado raiz, que não tem extremidades de entrada, mas possui extremidades de saídas. As saídas irão compor um grupo de nós interiores, também chamados de nós de teste ou internos, que, por sua vez, também possuem extremidades de saídas. Essas saídas levam aos nós terminais chamados nós folhas ou de decisão, os quais têm extremidades de entrada, mas não de saída. Cada nó interior divide o espaço de amostras em dois ou mais subconjuntos, conforme uma função discreta dos valores dos atributos de entrada, e contém um teste para um determinado atributo. Na forma mais simples e comum, cada teste considera um único atributo, tal que o espaço amostral é dividido de acordo com o valor do atributo. No caso de atributos numéricos, a condição se refere a um intervalo de valores do atributo. Cada galho descendente do nó interno corresponde a um possível valor do atributo (MAIMON e ROKACH, 2010). Cada percurso na árvore (do nó raiz a um nó folha) corresponde a uma regra de classificação. Os nós terminais representam o rótulo para o qual o objeto está sendo classificado, ou seja, a classificação final (figura 23).

O processo de classificação é implementado por um grupo de regras que determinam o caminho a ser seguido, iniciando a partir do nó raiz e terminando em um nó folha. Para cada nó interior uma decisão tem que ser tomada sobre o caminho para o próximo nó. A natureza das decisões sendo tomadas, bem como a sequência de atributos ocorrendo dentro da árvore, afetará os resultados da classificação. Além disso, a eficiência e a performance da abordagem são afetadas pelo algoritmo de indução da árvore de decisão (TSO e MATHER, 2009).

A criação de uma árvore de decisão envolve três tarefas: encontrar a estrutura ótima para a árvore, escolher o subconjunto ótimo de atributos para cada nó e selecionar a regra de decisão a ser usada em cada nó (RICHARDS e JIA, 2006; TSO e MATHER, 2009).

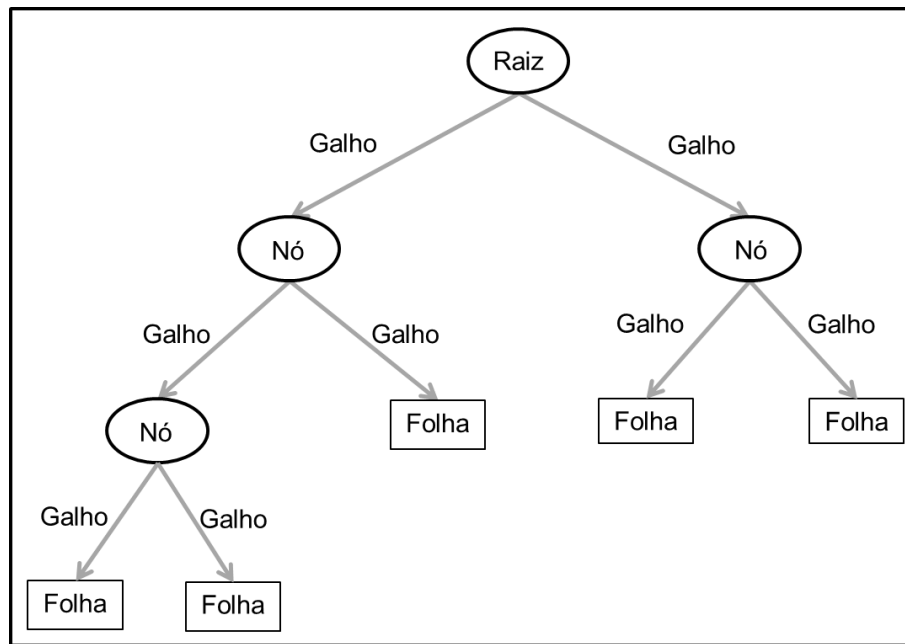


FIGURA 23 – REPRESENTAÇÃO GRÁFICA DE UMA ÁRVORE DE DECISÃO  
 FONTE: A AUTORA (2015)

O aprendizado do algoritmo pode ser realizado pelo método supervisionado, não supervisionado ou semissupervisionado. Nos três casos são necessárias amostras de treinamento para que o algoritmo de aprendizado aprenda o conceito desejado. No aprendizado supervisionado, as amostras representam corretamente as classes desejadas. No aprendizado não supervisionado, as amostras são aleatórias, cabendo ao algoritmo separar as mesmas em grupos, em função de suas similaridades e diferenças. O aprendizado semissupervisionado inclui algumas amostras rotuladas e muitas amostras não rotuladas, em virtude da dificuldade de se analisar os exemplos um a um em busca do rótulo verdadeiro (ZHOU e LI, 2010).

O objetivo principal é encontrar a árvore de decisão ótima, coerente com os exemplos de treinamento, atingindo-se uma classificação correta com um número pequeno de testes, minimizando o número de nós e minimizando a profundidade média. Uma estrutura ótima pode visar uma taxa de erro mínima, um número mínimo de nós, ou um percurso mínimo para decidir como dividir as classes em cada nó (TSO e MATHER, 2009; MAIMOM e ROKACH, 2010). Para tanto, deve-se testar o atributo de maior importância em primeiro lugar, ou seja, o atributo que influencia predominantemente a classificação de determinado exemplo (RUSSEL e NORVIG,

2003).

A complexidade da árvore irá afetar crucialmente a acurácia da mesma e pode ser medida pelo número total de nós, número total de folhas, profundidade da árvore e número de atributos usados. A complexidade é controlada pelo critério de parada usado e pelo método de poda empregado (BREIMAN *et al.*; 1984).

A seleção dos melhores atributos discriminantes para cada classe e dos critérios de divisão de cada nó são as principais decisões a serem tomadas no processo de indução de árvores de decisão. Essa seleção é realizada por um algoritmo indutor da árvore de decisão. Esse algoritmo segue a estrutura TDIDT - *Top-Down Induction of Decision Trees* (QUINLAN, 1986), ou seja, de cima para baixo, de forma recursiva, e usa a estratégia “dividir-para-conquistar” (QUINLAN, 1993), ou seja, um problema complexo é decomposto em subproblemas mais simples. Para selecionar o atributo que tenha o maior poder de discriminação entre as classes, bem como a ordem de inclusão dos atributos na árvore, existem vários critérios univariados, os quais podem ser caracterizados em (MAIMOM e ROKACH, 2010):

- de acordo com a origem da medida: teoria da informação, dependência e distância, e
- de acordo com a estrutura da medida: critério baseado na impureza, critério baseado na impureza normalizada e critério binário.

Um dos critérios baseados em impureza, comumente utilizado, é a heurística para escolha do atributo denominada ganho de informação. Esse critério mede a redução da entropia causada pela partição dos exemplos de acordo com os valores do atributo. Ou seja, o ganho de informação representa a diferença entre a quantidade de informação necessária para uma predição correta e as correspondentes quantidades acumuladas dos objetos resultantes após a introdução de um novo teste para o valor de determinado atributo. Para definir o ganho de informação é preciso usar o conceito de medida de entropia (QUINLAN, 1986).

A entropia é uma medida que indica a desordem da informação contida em um conjunto de dados, ou seja, caracteriza a aleatoriedade (impureza) de uma coleção arbitrária de exemplos. A construção de uma árvore de decisão é guiada pelo objetivo de diminuir a entropia.

Sendo:  $T = PE \cup NE$ , onde PE é o conjunto de exemplos positivos (ou verdadeiros) e NE o conjunto de exemplos negativos (ou falsos);  $p = |PE|$  e  $n = |NE|$  onde  $|PE|$  e  $|NE|$  representam a cardinalidade (número de elementos do conjunto) de PE e NE respectivamente;  $p_{\oplus} = p/(p+n)$  = probabilidade de um exemplo pertencente ao nó ser um exemplo positivo, e  $p_{\ominus} = n/(p+n)$  = probabilidade de um exemplo pertencente ao nó ser um exemplo negativo, então a entropia pode ser definida como a quantidade de informação necessária para decidir se um exemplo pertence a PE ou a NE (WU, 1993). Dado um conjunto S, contendo exemplos positivos e negativos que definem o conceito a ser aprendido, a entropia relativa dos dados desse conjunto S é indicada por (BREIMAN *et al.*, 1984; QUINLAN, 1986 e 1993):

$$\text{Entropia}(S) = - p_{\oplus} \cdot \log_2 p_{\oplus} - p_{\ominus} \cdot \log_2 p_{\ominus}, \text{ para } p \neq 0 \text{ e } n \neq 0 \quad (17)$$

sendo:

- $p_{\oplus}$ : proporção de exemplos positivos em S (sim)
- $p_{\ominus}$ : proporção de exemplos negativos em S (não)

A entropia dos segmentos descendentes de um nó pai da árvore é acumulada de acordo com o peso de suas contribuições na entropia total da ramificação, ou seja, de acordo com o número de exemplos cobertos pela ramificação. A métrica que é usada para escolher o melhor teste deve avaliar o quanto de desordem será reduzido com o novo segmento e como será a ponderação da desordem em cada segmento (WU, 1993).

Para avaliar o quanto de desordem é reduzido através de um novo teste, basta calcular a entropia em cada novo segmento (nó filho) criado por cada ramo, onde cada ramo é associado com um valor do atributo sendo testado.

O ganho de informação de um atributo A em um conjunto de amostras de treinamento S é dado por (QUINLAN, 1986 e 1993):

$$\text{Ganho (S, A)} = \text{Entropia (S)} - \sum_{V \in \text{Valores (A)}} \frac{|S_V|}{|S|} \text{Entropia (S}_V) \quad (18)$$

sendo:

$|S_V|$  denota o subconjunto de S para os quais o atributo A tem valor V;

O critério de ganho seleciona como atributo-teste aquele que maximiza o ganho de informação. A desvantagem que esse critério apresenta é que ele dá preferência a atributos com muitos valores possíveis. No caso de se ter um atributo totalmente irrelevante, poderia ser criado um nó para o mesmo, o qual teria um ganho máximo mesmo sendo totalmente inútil. Outro critério que pode ser usado é a taxa de ganho de informação, dada por (QUINLAN, 1993; TSO e MATHER, 2009):

$$\text{Taxa de ganho (S)} = \text{Ganho (S, A)} / \text{informação\_corte (S)} \quad (19)$$

$$\text{Informação\_corte (S)} = -\sum_{i=1}^N \left( \frac{|T_i|}{T} \right) * \log_2 \left( \frac{|T_i|}{T} \right) \quad (20)$$

A informação\_corte (S) é a quantidade de informação em potencial associada com o fato de um teste do atributo S particionar T em N subconjuntos (N = número de partições / segmentos criados pelo teste). A razão de ganho é o ganho de informação relativa (ponderado). Quando o valor da entropia do nó é igual a zero, a razão não será definida. Esse critério favorece atributos cujo valor de entropia é pequeno.

Apesar de o critério ganho de informação apresentar bons resultados, ele apresenta um viés que beneficia os testes com muitas saídas, ou seja, atributos com muitos valores. Esse problema pode ser corrigido através da normalização do ganho aparente atribuído ao teste com várias saídas. Já o critério da taxa de ganho

expressa a proporção de informação gerada pela ramificação que parece ser útil para o processo de classificação (QUINLAN, 1993).

O algoritmo CART (*Classification and Regression Tree*), proposto por Breiman *et al.* (1984), pode usar critérios univariados ou multivariados para a indução da árvore, como ganho de informação, razão de ganho de informação ou índice Gini, gerando sempre uma árvore binária, ou seja, somente dois galhos podem ser gerados a cada divisão. No caso de um único critério, em cada teste apenas uma característica é usada. No caso do critério multivariado, em cada divisão de um nó podem ser realizadas combinações lineares de características. Um grupo de funções lineares discriminantes é estimado para cada nó interior de uma árvore de decisão multivariada, com os coeficientes para a função linear discriminante de cada nó interior sendo estimados a partir dos dados de treinamento. As fronteiras de decisão geradas por uma árvore de decisão multivariada serão mais flexíveis que as formadas por árvores de um único critério (TSO e MATHER, 2009).

Em função do(s) critério(s) de indução utilizado(s) o algoritmo segue os passos subsequentes para a classificação dos dados (HAN, KAMBER e PEI, 2012):

1) A árvore inicia em um nó  $N$ , que representa as amostras de treinamento  $D$ . Se as amostras de  $D$  forem todas de uma mesma classe, então o nó  $N$  torna-se uma folha e é rotulado com aquela classe. Do contrário, o algoritmo inicia o método de seleção de atributos para determinar o melhor critério de divisão.

2) As amostras dos subconjuntos de  $D$  são divididas, em função do atributo  $A$  que tem  $v$  valores distintos ( $a_1, a_2, \dots, a_v$ ).

- Se o valor  $v$  for discreto e igual ao valor do atributo  $A$ , um galho é criado para cada valor conhecido  $a_j$  de  $A$ . Se todas as amostras têm o mesmo valor para  $A$ , então  $A$  não deve ser considerado em uma futura divisão das amostras, sendo então removido da lista de atributos.

- Se o valor  $v$  for contínuo, então dois resultados são possíveis, correspondentes às condições  $A \leq \text{limiar de divisão}$  e  $A \geq \text{limiar de divisão}$ . O limiar de divisão corresponde ao ponto médio de dois valores adjacentes conhecidos de  $A$ ,

podendo não ser um valor pré-existente de  $A$  contido nos dados de treinamento. Dois ramos são gerados no nó  $N$ . As amostras são divididas de forma que  $D_1$  corresponda a  $A \leq \text{limiar de divisão}$ , e  $D_2$  contenha o restante dos dados.

- Se o valor for discreto e uma árvore binária deva ser produzida, então o teste no nó  $N$  será da forma " $A \in S_A?$ ", sendo  $S_A$  o subconjunto de valores conhecidos de  $A$ . Se determinada amostra tem valor  $a_j$  de  $A$  e se  $a_j \in S_A$ , o teste no nó  $N$  é satisfeito. Dois ramos são gerados a partir do nó  $N$ , contendo os subconjuntos  $D_1$  (subconjunto de  $D$  que satisfaz o teste) e  $D_2$  (subconjunto de  $D$  que não satisfaz o teste).

3) O processo se repetirá recursivamente até que uma das três condições de finalização seja verdadeira:

- Todas as amostras de treinamento  $D$  pertencem à mesma classe;
- Não existem atributos remanescentes a partir dos quais as amostras de  $D$  possam ser posteriormente divididas. Neste caso, o princípio da maioria é empregado, convertendo-se o nó  $N$  em uma folha e rotulando-a com a classe mais frequente em  $D$ .
- Não existem amostras para um dado galho, isto é, uma partição  $D_j$  está vazia. Neste caso, a folha é criada com a maioria das classes em  $D$ .

As árvores de decisão, devido à existência de muitos atributos ou classes, podem se tornar complexas. Apesar de o usuário poder usar condições pré-definidas, como profundidade máxima ou número mínimo de nós, para limitar o processo de indução, na prática, as árvores resultantes podem ter galhos longos e desiguais, inclusive influenciados por ruídos (*outliers*) nos dados. Além disso, a árvore pode estar ajustada demais (*overfitted*) aos dados de treinamento, não permitindo ao modelo generalizar. Há que se ressaltar que, geralmente, a árvore induzida pelo algoritmo CART tende a ser superajustada. Em virtude disso, métodos de refinamento ou ajuste das árvores são necessários. Esses métodos são conhecidos como poda (*pruning*) e buscam solucionar o problema de sobreajuste (*overfitting*) dos dados, por meio de medidas estatísticas para remover os ramos

menos confiáveis (TSO e MATHER, 2009). O objetivo é melhorar a taxa de acerto do modelo para novos exemplos, os quais não foram utilizados no treinamento. As árvores podadas costumam ser menores, menos complexas, mais rápidas e mais eficientes na classificação, o que facilita sua compreensão (HAN, KAMBER e PEI, 2012).

A poda pode ser realizada pela pré-poda ou pela pós-poda. A pré-poda é realizada interrompendo-se a construção da árvore, tomando-se a decisão de não mais dividir um subconjunto de amostras em um determinado nó, tornando-o assim em uma folha. Quando a poda é realizada após a construção completa da árvore, o método é denominado pós-poda. Uma subárvore em um determinado nó é podada removendo seus galhos e substituindo-os por folhas. A folha é rotulada com a classe mais frequente dentre aquelas contidas na subárvore que está sendo substituída (WITTEN, FRANK e HALL, 2011). Segundo Quinlan (1987), a pós-poda é mais lenta, porém mais confiável que a pré-poda.

Dentre os métodos de poda existentes, podem-se citar o *reduced error pruning*, o *pessimistic error pruning* e o *error-based pruning*, propostos por Quinlan (1986 e 1993). O método *cost complexity pruning* foi proposto por Breiman *et al.* (1984) e o método Bayesiano *minimal error pruning* foi proposto em 1991 por Niblett e Bratko (apud TSO e MATHER, 2009; PATIL, WADHAI e GOCHALE, 2010).

O algoritmo CART realiza a pós-poda por meio da redução do fator custo-complexidade, o qual consiste em podar a árvore para trás, criando uma sequência aninhada de árvores, diminuindo em complexidade (BREIMAN *et al.*, 1984). Esse método tenta encontrar o melhor compromisso entre os erros estimados a partir de um conjunto de poda ou validação cruzada e o tamanho da árvore de decisão.

A dificuldade na execução da poda é a seleção de um limiar apropriado, pois um limiar alto pode resultar em uma árvore muito simplificada, e um limiar muito baixo pode resultar em pouca simplificação (HAN, KAMBER e PEI, 2001).

Detalhes sobre os métodos de indução e poda, bem como formulação matemática, podem ser encontrados em Breiman e outros autores (1984), Quinlan



(1986, 1987 e 1993), Wu (1993), Russel e Norvig (2003), Mitchell (1997), Berry e Linoff (2004), Tso e Mather (2009), Maimom e Rokach (2010), Patil, Wadhai e Gokhale (2010), Witten, Frank e Hall (2011), Han, Kamber e Pei (2012).

Neste estudo, para a classificação por árvore de decisão, foi necessário selecionar um nível de segmentação para o qual o procedimento foi realizado. Na sequência, foram coletadas amostras de treinamento, no nível selecionado, e indicados os atributos a serem considerados. A partir das amostras, ocorreu o treinamento da árvore de decisão. No passo seguinte, a árvore de decisão foi gerada com base nos atributos mais relevantes e de forma a gerar a menor árvore possível. A árvore de decisão foi então aplicada à imagem para realização da classificação automática.

Para as duas áreas de estudo o nível de segmentação selecionado foi o de FE=50. A escolha se deu em função da análise dos objetos mais representativos na região da voçoroca.

Para o treinamento da árvore de decisão, a fim de se evitar que a mesma se torne superadaptada a uma determinada classe, é necessário que sejam fornecidas amostras em quantidades parecidas para cada classe. Seguindo este critério, para a área de estudo A1 foram selecionadas 53 amostras, sendo 8 da classe voçoroca, 12 da classe solo exposto, 10 da classe vegetação rasteira, 11 da classe vegetação arbórea, 9 da classe sombra e 3 da classe água (menor quantidade em função do número limitado de objetos pertencentes a essa classe). Para a área de estudo A2 foram selecionadas 39 amostras, sendo 10 da classe voçoroca, 10 da classe solo exposto, 10 da classe vegetação e 9 da classe sombra.

Os atributos submetidos à mineração de dados, analisados qualitativamente durante o planejamento da classificação, estão ilustrados nos quadros 4 (área de estudo A1) e 5 (área de estudo A2).

<b>BASEADOS NO PIXEL</b>	<b>VALORES DAS BANDAS</b>	<b>GEOMÉTRICOS</b>	<b>TEXTURA DE HARALICK</b>
RAZÃO: Intensidade; MDS; Azul; Declividade; Verde; Infravermelho	MÉDIA: Brilho; Intensidade; MDSN; Máxima Diferença; NDVI; Azul; Declividade; Verde; Infravermelho; Vermelho	EXTENSÃO: Relação Comprimento/ largura	GLCM (quick 8/11): Homogeneidade; Contraste; Média
MÍNIMO VALOR NDVI; Infravermelho; Vermelho	DESVIO-PADRÃO Declividade	FORMA Densidade; Adaptação a um retângulo	
MÁXIMO VALOR NDVI; Verde; Infravermelho; Vermelho	ASSIMETRIA MDS; Azul; Declividade; Verde; Infravermelho; Vermelho		
MÉDIA DA BORDA INTERNA Intensidade; MDSN; NDVI; Azul; Declividade; Verde; Infravermelho; Vermelho			
MÉDIA DA BORDA EXTERNA MDSN; NDVI; Declividade; Vermelho			
CONTRASTE DA BORDA Azul; Verde; Infravermelho; Vermelho			
MÉDIA CIRCULAR MDSN; NDVI; Azul; Declividade; Verde; Infravermelho; Vermelho			

QUADRO 4 – ATRIBUTOS SUBMETIDOS À MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

<b>VALORES DAS BANDAS</b>	<b>TEXTURA DE HARALICK</b>
MÉDIA: Azul; Brilho; Declividade; IVBI; Intensidade; MDS; MDSN; MDT; Máxima Diferença; Vermelho; Verde	Entropia GLDV Homogeneidade GLCM (quick 8/11 - todas as direções) Contraste GLCM (quick 8/11 - todas as direções) Desvio-padrão GLCM (quick 8/11 – direção 135°) Entropia GLDV (quick 8/11 - todas as direções) Média GLDV (quick 8/11 - todas as direções)

QUADRO 5 – ATRIBUTOS SUBMETIDOS À MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

Os atributos foram selecionados, por análise visual, em função de sua capacidade de discriminar os objetos nas diferentes classes. Para a área de estudo A1, o uso do solo pode ser bem definido, por se tratar de área destinada à pecuária

e à agricultura. As regiões com campos de cultivo e de pastejo, com áreas de reserva florestal e de corpos d'água apresentam-se bem delimitadas. Já para a área de estudo A2, os elementos aparecem dispersos, apresentando muitas árvores isoladas, por exemplo, em meio tanto a áreas de solo exposto como em áreas com vegetação rasteira. A vegetação rasteira é exígua e, portanto, muito misturada à classe de solo exposto. A vegetação arbórea apresenta muitas árvores isoladas sem folhagem, o que dificulta sua discriminação em função dos dados espectrais, somente sendo reconhecidas com auxílio do MDSN. A porção do rio que aparece na cena encontrava-se, na ocasião da tomada dos dados, com baixíssima vazão, mostrando o fundo do rio como solo exposto.

Como as áreas de estudo apresentam características bastante distintas, tanto em termos de classes existentes na cena como em relação à resposta espectral dos alvos, ao uso do solo e às bandas imageadas disponíveis para o processamento, os atributos selecionados para cada área também são distintos. Para a área de estudo A1 foram selecionados atributos relacionados à resposta espectral/altimétrica de cada banda, geométricos, de textura e baseados no pixel. Para a área de estudo A2 apenas os atributos espectrais e de textura mostraram-se relevantes para a discriminação das classes.

A mineração dos dados foi realizada com auxílio do algoritmo CART. As árvores de decisão obtidas foram usadas para classificar as áreas de estudo, em um procedimento automático de classificação. Tanto o procedimento de geração da árvore quanto da aplicação da mesma, foram realizados com auxílio do programa eCognition. As árvores de decisão foram usadas para a seleção prévia dos atributos mais relevantes, para o estabelecimento da base de regras e para uma classificação preliminar, o que agiliza o processo de classificação de objetos por meio de lógica fuzzy e hierarquia.

#### 4.3.5 Classificação de objetos por meio de lógica fuzzy e hierarquia

A lógica fuzzy tem por objetivo modelar modos de raciocínio aproximados ao invés de precisos, tendo os casos precisos como situações limite. Trata-se, portanto, de uma abordagem matemática para quantificar estados de incerteza. Dentro de uma lógica booleana, somente as situações de verdadeiro (1) e falso (0) podem ser representadas. Na lógica fuzzy, a situação pode assumir um valor qualquer no intervalo entre 0 e 1 (ZADEH, 2008). A lógica fuzzy refere-se ao raciocínio subjetivo, difuso.

Com o propósito de representar o conhecimento vago, não determinístico, Lotfi Asker Zadeh (1965 e 2008) aperfeiçoou a teoria de conjuntos fuzzy de Jan Lukasiewicz, de 1920, desenvolvendo a *lógica fuzzy*, também conhecida como lógica difusa ou lógica nebulosa. Ela é uma generalização do conceito da teoria clássica dos conjuntos, dando suporte aos modos de raciocínio que são aproximados ao invés de exatos. A lógica fuzzy fornece uma maneira de solucionar problemas de classificação e representação do conhecimento em um ambiente ambíguo.

Um conjunto fuzzy é uma classe de objetos com um contínuo de graus de pertinência. Tal conjunto é caracterizado por uma função (característica) de pertinência, a qual assinala a cada objeto um grau de intervalo de pertinência entre zero e um. As noções de inclusão, união, intersecção, complemento, relação, convexidade, etc, são estendidas para tais conjuntos, e várias propriedades dessas noções no contexto de conjuntos fuzzy são estabelecidas. (ZADEH, 1965, p.338)

A saída, ou resultado, de um sistema de classificação fuzzy é uma classificação fuzzy, na qual o grau de pertencimento para cada classe de uso ou cobertura do solo é dado para cada objeto. O grau de pertencimento máximo determina a classificação final para construir uma interface com sistemas *crisp* (booleanos). Os sistemas fuzzy consistem de três passos principais: fuzzificação, inferência ou base de regras fuzzy e defuzzificação (figura 24).




FIGURA 24 – ARQUITETURA BÁSICA DE UM SISTEMA FUZZY  
 FONTE: ADAPTADO DE TSO E MATHER, 2009

A partir dos dados de entrada, são estabelecidas as funções de pertencimento fuzzy, no processo de fuzzificação. Na sequência, em função de classes pré-definidas, é estabelecida a base de regras fuzzy, com combinações de conjuntos fuzzy e das funções de pertencimento, de forma a calcular o grau de pertencimento de cada dado de entrada para cada classe. O último processo, a defuzzificação, permite converter os valores de retorno do cálculo efetuado no passo anterior, para um formato *crisp*, permitindo que a classificação seja convertida em um mapa temático de uso e cobertura do solo (TSO e MATHER, 2009).

Na classificação fuzzy obtém-se o grau de possibilidade de um pixel pertencer a uma determinada classe. Na classificação baseada em probabilidade obtém-se a probabilidade de um pixel pertencer a uma determinada classe. A possibilidade fornece informação sobre um objeto distinto. A probabilidade depende de estatísticas e fornece informação sobre muitos objetos. Enquanto a probabilidade de todos os possíveis eventos resulta no número um, isto não é necessariamente verdadeiro para possibilidades (BAATZ *et al.*, 2001).

A fuzzificação descreve a transição de um sistema *crisp* para um sistema fuzzy, envolvendo a divisão do espaço de características de entrada em subespaços fuzzy, cada um especificado por uma função de pertencimento. A definição das funções de pertencimento, adequadas à aplicação e às características dos dados formadores do conjunto, é crucial para uma classificação de sucesso. Isso permite a

introdução do conhecimento especialista no sistema. Quanto melhor o conhecimento sobre o sistema real é modelado pelas funções de pertencimento, melhor será o resultado final da classificação.

A função de pertinência deve apresentar valor igual a 1 no centro do conjunto, para os pontos que pertencem exatamente ao conjunto. A função deve diminuir de forma apropriada, condizente com o comportamento dos pontos pertencentes ao conjunto, diminuindo do centro para a(s) borda(s).

Uma função de pertinência pode assumir várias formas (contanto que a função possa mapear as entradas para o intervalo  $[0, 1]$ ). Dentre as funções mais frequentemente usadas estão as lineares (monotônica, triangular e trapezoidal), sinusoidais e gaussianas. A seleção da função de pertinência e a largura de cada subespaço fuzzy dependem de cada dado a ser classificado.

No programa eCognition estão implementadas as funções ilustradas na figura 25. O programa sugere a função de pertinência de acordo com a amostra de treinamento fornecida, e é possível ajustar o intervalo de valores, bem como a função.













	maior que		intervalo linear (triangular)
	menor que		intervalo linear (triangular invertida)
	maior que (booleana)		singleton (exatamente um valor)
	menor que (booleana)		gaussiana aproximada
	maior que (linear)		aproximadamente o intervalo
	menor que (linear)		intervalo total

FIGURA 25 – FUNÇÕES DE PERTINÊNCIA FUZZY DISPONÍVEIS NO PROGRAMA ECOGNITION  
FONTE: A AUTORA (2015)

A base de regras fuzzy é uma combinação de regras fuzzy, as quais combinam diferentes conjuntos fuzzy. As regras mais simples são dependentes de apenas um conjunto. As regras fuzzy são regras do tipo se-então (*if-then*). Se uma condição é totalmente satisfeita, uma ação é tomada. A inferência requer o cálculo da intensidade de cada regra sendo disparada.

Uma base de regras fuzzy possibilita uma classificação fuzzy, a qual consiste de valores de retorno discretos para cada uma das classes de saída consideradas. Esses valores representam o grau de atribuição à classe. Quanto maior o valor de retorno para a classe mais provável, mais confiável a atribuição. O valor mínimo de pertencimento que um objeto precisa para ser atribuído a uma classe pode ser definido previamente. Quanto maior a diferença entre o valor mais alto e o segundo valor mais alto, mais clara e estável a classificação.

Uma metodologia de classificação baseada em regras busca incorporar o conhecimento humano à tarefa de classificação. Os métodos baseados em regras tradicionais podem ser considerados como versões *crisp* de métodos fuzzy, ou seja, cada regra tem igual peso (ou efetividade). Esse tipo de classificador *crisp* baseado em regra pode apresentar alguns problemas. Por exemplo, no caso de uma base de regras de decisão hierárquica, a classificação é implementada percorrendo a árvore de decisão até que um nó final seja alcançado. Esse processo é equivalente a definir gradualmente partições *crisp* do espaço de solução. Se as fronteiras entre as classes são bem definidas, a base de regras de decisão hierárquica pode apresentar bons resultados. Entretanto, em imagens de sensoriamento remoto, as classes frequentemente apresentam sobreposição umas com as outras. Nesse caso, usando-se uma metodologia de árvore de decisão *crisp*, podem ocorrer erros na classificação dos pixels que se encontram na zona de sobreposição. Se a base de regras *crisp* é inferida simultaneamente ao invés de hierarquicamente, o problema de conflito de regras é também possível de acontecer (TSO e MATHER, 2009).

A defuzzificação é o processo reverso da fuzzificação. Ele fornece uma classificação *crisp*. Para produzir resultados como mapas, para aplicações padrão de cobertura e uso da terra, os resultados fuzzy têm que ser transladados de volta para um valor *crisp*, o que significa que um objeto ou é atribuído a uma classe ou não. No passo da classificação, usualmente a classe com o maior grau de pertinência é escolhida. Para este tipo de saída, as medidas de incerteza da classificação fuzzy são perdidas. Se um grau de pertinência de uma classe está

abaixo de certo valor, a classificação não é realizada, de forma a garantir uma confiabilidade mínima (BAATZ *et al.*, 2001).

Os métodos mais populares de defuzzificação são: centro de gravidade (*center-of-gravity*) e meio do máximo (*mean-of-maximum*).

Na classificação hierárquica, a descrição das classes, bem como suas entidades e relações, é feita dentro de uma hierarquia de classes a qual, simultaneamente, age como uma base de conhecimento descrevendo o conteúdo da imagem. Dentro da hierarquia de classes é possível criar subclasses e superclasses, as quais permitem, por um lado, herdar as propriedades das características a partir das superclasses para as subclasses e, por outro lado, agrupar classes semanticamente (HOFMANN e REINHARDT, 2000).

A classificação hierárquica, integrante da FNEA, baseia-se em lógica fuzzy e é realizada com base nos diferentes níveis provenientes da segmentação multirresolução, sendo, portanto, um método orientado a objeto. As feições são classificadas de acordo com o nível em que melhor forem segmentadas. A classificação é realizada com base na rede hierárquica estabelecida, nas amostras selecionadas para treinamento dos algoritmos e nos atributos selecionados como descritores para cada classe (BAATZ e SCHÄPE, 1999). A edição interativa das funções de pertinência fuzzy permite a formulação de conhecimento e conceitos.

Para este estudo, a partir das árvores de decisão obtidas, foram selecionados os atributos mais relevantes na discriminação das classes. A árvore de decisão resultou, também, na explicitação das regras para classificação, sugerindo uma hierarquia, através da divisão em nós das árvores. Com base na hierarquia sugerida pela árvore e no conhecimento especialista da analista, propôs-se uma rede hierárquica, selecionando-se os níveis de segmentação e as classes a serem discriminadas em cada nível. Além dos atributos indicados pelas árvores de decisão, foram incorporados outros atributos, de acordo com o conhecimento especialista, e regras de pertinência fuzzy na discriminação de cada classe. Realizou-se então a classificação hierárquica para as duas áreas de estudo.



#### 4.3.6 Avaliação da classificação

Como a classificação é uma generalização das informações constantes em uma cena, é necessário realizar uma avaliação para expressar o quão confiável é o mapa temático dela derivado. A avaliação pode ser realizada comparando-se o resultado com um mapa de referência, o qual se assume como correspondente à verdadeira classificação, ou com dados levantados no local da cena, referentes à verdade de campo. Quando se usa o método supervisionado, pode-se também realizar a avaliação da classificação em função dos dados de treinamento (amostras), ou destes em conjunto com dados de teste (validação cruzada).

Para as duas áreas de estudo foram selecionadas amostras de verificação e foram geradas as matrizes de confusão e calculados os índices kappa e de acurácia global. A seleção do número de amostras baseou-se em padrões estatísticos para obterem-se amostras representativas. Uma amostra é representativa se as unidades que a constituem forem escolhidas por um processo tal que todos os membros da população tenham a mesma probabilidade de fazer parte da amostra. Para cada área de estudo, verificou-se o número de objetos segmentados, no fator de escala selecionado para a classificação do nível hierárquico mais detalhado, atribuindo-se esse valor à população total. A amostra aproximada foi então calculada por (GONÇALVES, 2002; FERREIRA, 2009):

$$n_0 = \frac{Z^2 \cdot p \cdot (1-p)}{e^2} \quad (21)$$

sendo:

$n_0$  = 1ª aproximação do tamanho da amostra calculada

$Z$  = Valor crítico. Corresponde ao desvio do valor médio aceito para se alcançar o nível de confiança desejado. Em função do nível de confiança desejado, usa-se um valor determinado que é dado pela forma da distribuição de Gauss. Os valores mais frequentes são: Nível de confiança 90%  $\rightarrow Z = 1,645$ ; Nível de confiança 95%  $\rightarrow Z =$

1,96; Nível de confiança 99%  $\rightarrow Z = 2,575$

$p$  = é a proporção que se deseja encontrar. Quando uma população é muito uniforme, a convergência para uma população normal é mais precisa, permitindo reduzir o tamanho da amostra. No entanto, quando não se tem ideia do que se deve esperar, a opção mais prudente é usar o pior cenário: a população se distribui em partes iguais, logo  $p=50\%$ .

$e$  = margem de erro máximo que se deseja admitir. O Erro amostral corresponde à diferença entre o valor estimado e o verdadeiro valor. Frequentemente o valor definido é 5%.

Após o cálculo da 1ª aproximação do tamanho da amostra, faz-se a correção por (GONÇALVES, 2002; FERREIRA, 2009):

$$n = \frac{n_0 * N}{n_0 + (N - 1)} \quad (22)$$

sendo  $N$  = população.

A matriz de erros, também conhecida como tabela de contingência ou matriz de confusão, é uma maneira de representação da avaliação da classificação e mostra os conflitos que existem entre as classes. Nessa matriz, as linhas correspondem aos dados de referência (ref.) e as colunas aos dados classificados (classif.), quando se está confrontando um mapa de referência com o mapa advindo da classificação. Quando a avaliação é realizada em função dos dados de treinamento (trein.), as linhas correspondem às amostras selecionadas (assumidas como referência) e as colunas correspondem aos dados classificados. Cada célula da matriz apresenta o valor do pixel que deveria ser classificado como a classe especificada na linha e que foi classificado segundo a classe especificada na coluna. Para uma classificação perfeita, a matriz apresenta somente os valores da diagonal principal, o que dificilmente ocorre. Os pixels classificados incorretamente são os que se encontram fora da diagonal principal ( $x$ ) (CHUVIECO e HUETE, 2010). O quadro 6 ilustra uma matriz de confusão com seus elementos.

Classe	1 (classif.)	2 (classif.)	3 (classif.)	4 (classif.)	Soma parcial (SC)
1 (ref./trein.)	$M_{ij}$	x	x	x	
2 (ref./trein.)	x	$M_{ij}$	x	x	
3 (ref./trein.)	x	x	$M_{ij}$	x	
4 (ref./trein.)	x	x	x	$M_{ij}$	
Soma parcial (SL)					NT

QUADRO 6 – MATRIZ DE CONFUSÃO  
FONTE: A AUTORA, 2015

A partir da matriz de erros, pode-se calcular a qualidade global (Q) da classificação (CENTENO, 2009; TSO e MATHER, 2009):

$$Q = \frac{NC}{NT} \quad (23)$$

sendo NC o número de pontos corretamente classificados (soma dos valores da diagonal principal) e NT o número total de pontos.

Para se obter a acurácia de cada classe separadamente, os conceitos de acurácia do produtor e do usuário podem ser usados. A acurácia do produtor está relacionada com os erros de omissão (EOM), que correspondem aos pixels pertencentes a uma determinada classe que foram erroneamente classificados como sendo de outra, ou seja, foram omitidos da classe assumida como verdadeira (CENTENO, 2009; TSO e MATHER, 2009):

$$EOM = \frac{SL(i) - M(ii)}{SLi} \quad (24)$$

sendo  $SL(i)$  a soma parcial da linha i, e  $M(i,i)$  o elemento da diagonal principal na linha i.

A acurácia do usuário está relacionada com os erros de inclusão (EIN), que correspondem aos pixels que foram incluídos na classificação e que não correspondem aos que foram assinalados como verdadeiros (CENTENO, 2009; TSO e MATHER, 2009):

$$EIN = \frac{SC(i) - M(ii)}{SCi} \quad (25)$$

sendo  $SC(i)$  a soma parcial da coluna  $i$ .

Outra forma de avaliar a acurácia da classificação é através do índice Kappa, ou coeficiente de concordância, proposto por Cohen em 1960, expresso por (CENTENO, 2009; TSO e MATHER, 2009):

$$k = \frac{N * \sum_{i=1}^M M(i,i) - \sum_{i=1}^M SL(i) * SC(i)}{N^2 - \sum_{i=1}^M SL(i) * SC(i)} \quad (26)$$

sendo  $N$  o número de amostras (ou observações) e  $M$  o número de classes. Um valor de kappa entre 0,8 e 1,0 expressa uma classificação excelente, entre 0,6 e 0,8 muito boa, entre 0,4 e 0,6 boa, entre 0,2 e 0,4 razoável, entre 0 e 0,2 ruim e abaixo de 0 péssima (LANDIS e KOCH, 1977).

Para kappa inferior a zero, não ocorre discriminação entre as classes e, em contra partida, quanto mais ele se aproxima do valor 1 melhor é a classificação. Um kappa igual a 1 ocorre somente quando não há erros de omissão e inclusão. O valor de kappa decresce à medida que os valores externos à diagonal principal crescem. Uma das vantagens para uso do kappa é de que ele incorpora a informação dos pixels mal classificados, e não apenas a dos bem classificados como a acurácia total (qualidade global).

Além das matrizes de confusão, para a área de estudo A1, foi gerado um mapa de referência por fotointerpretação visual, para a região da voçoroca, e o mesmo foi analisado em comparação aos mapas temáticos obtidos pelas classificações por árvore de decisão e hierárquica.

## 5 RESULTADOS E DISCUSSÕES

Na sequência são apresentados e discutidos os resultados obtidos em todas as etapas metodológicas.

### 5.1 PROCESSAMENTO DA NUVEM DE PONTOS ALS DA ÁREA DE ESTUDO A1

A primeira etapa do pré-processamento dos dados permitiu a rasterização dos dados ALS, gerando a imagem de intensidade (figura 26) e o MDS (figura 27). Dos valores de intensidade, 99,9904% encontram-se no intervalo de valor digital de 10 (pixels relativos a corpos d'água) a 870 (pixels relativos a solo exposto seco). Os demais valores (atingindo o valor máximo de 2560) podem ser considerados *outliers* não suprimidos durante os processamentos, mesmo excluindo-se os valores que diferiam mais que 3 desvios-padrão da vizinhança.

A partir do MDS é possível verificar que as altitudes variam de 819,10 m a 878,13 m na área de estudo A1. Na porção ao norte, onde há a presença de solo exposto com vegetação rasteira, estão as maiores altitudes da cena e o declive do terreno se dá em direção à área da voçoroca. No trecho mostrado na imagem (flecha azul na figura 27) há um desnível em torno de 13 m em uma distância horizontal de 192 m até a borda da cabeceira da voçoroca, o que resulta em uma vertente com inclinação de 3,87° ou 6,77%. A grande área da vertente, com pouca cobertura florestal, acentua o escoamento superficial, o que pode explicar, junto com outros fatores como o tipo de solo, a presença da voçoroca no local. Na porção superior direita da imagem podem-se perceber feições com altitudes em torno de 860 m a 870 m, que correspondem a copas de árvores. Isso evidencia que o uso apenas das informações do MDS não é suficiente para discriminar as feições, justificando a necessidade da geração de informações derivadas a partir do MDS, como o MDT e o MDSN.

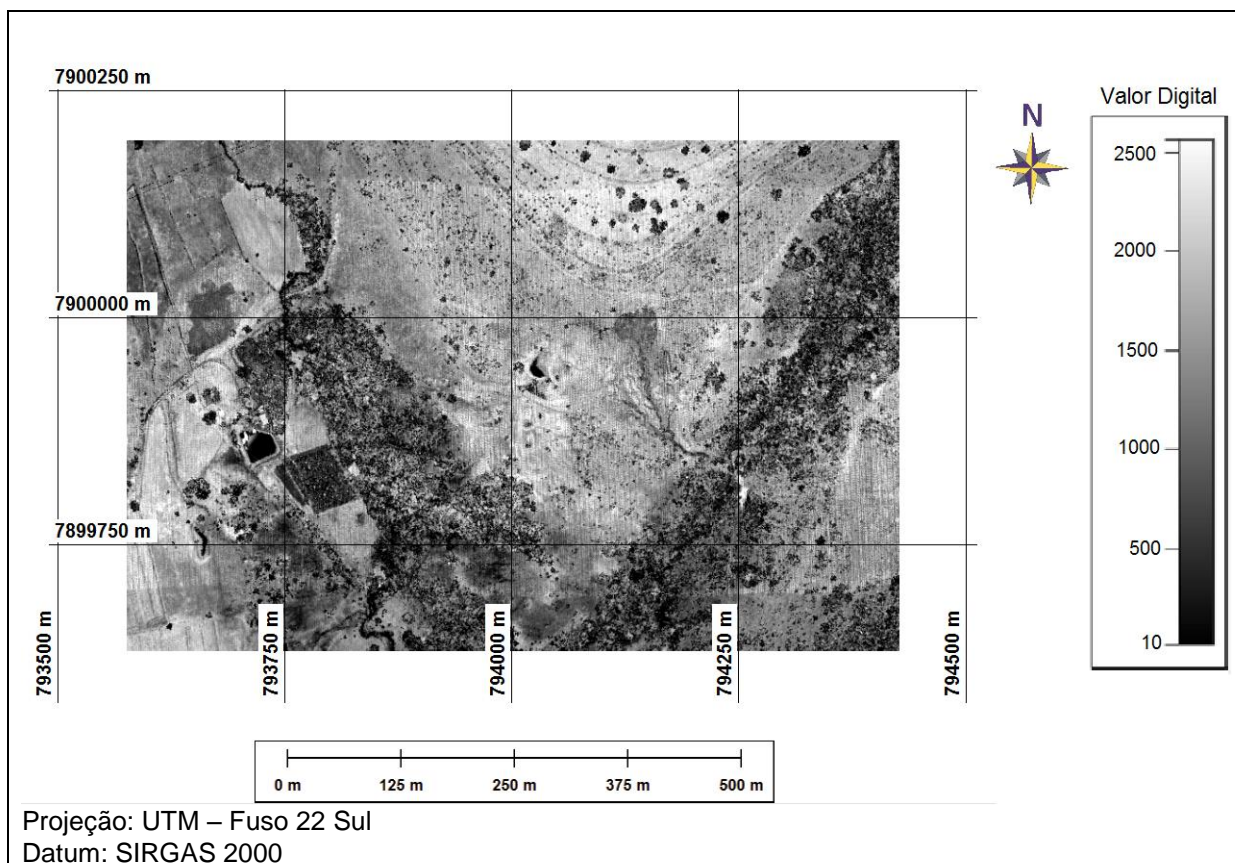


FIGURA 26 – IMAGEM DE INTENSIDADE DA ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

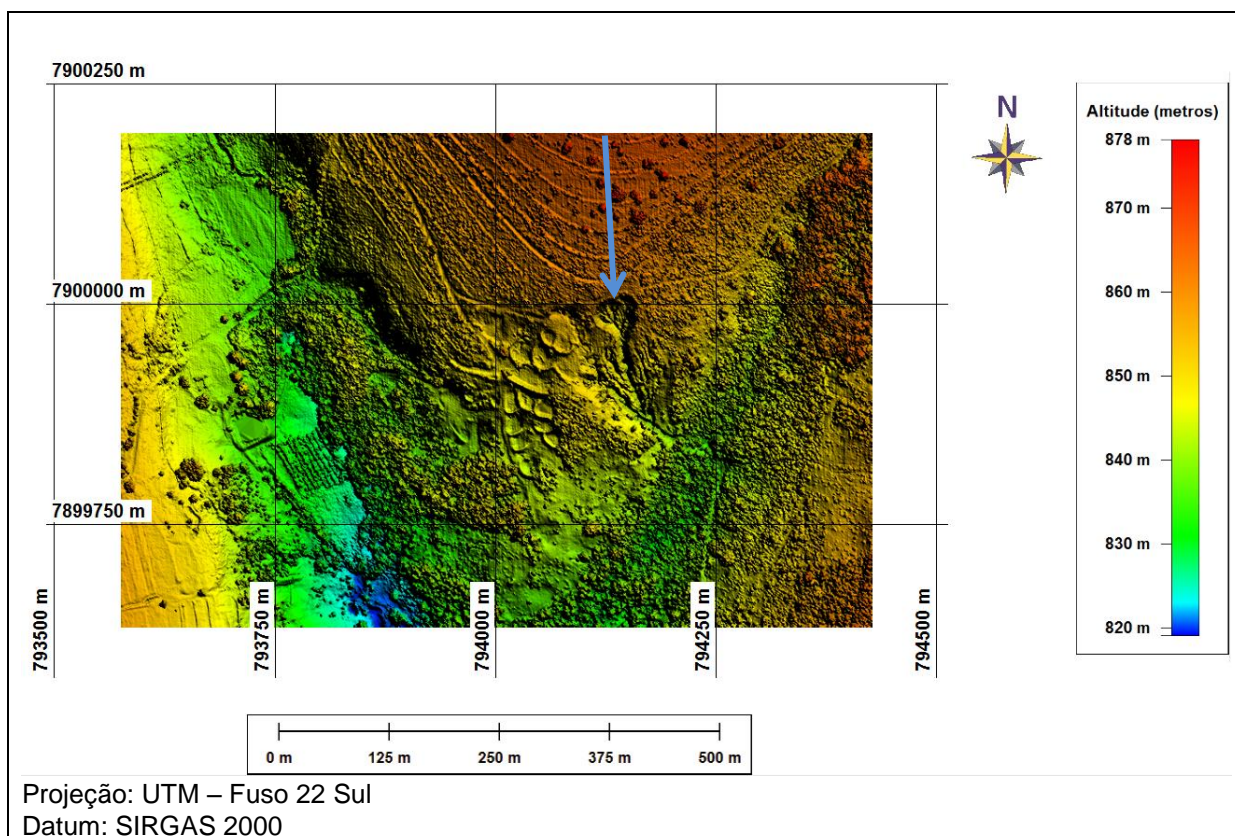


FIGURA 27 – MODELO DIGITAL DE SUPERFÍCIE DA ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

A geração do MDT foi realizada pela filtragem dos dados altimétricos com auxílio do programa ALDPAT. A figura 28 ilustra os resultados obtidos com a aplicação dos diferentes filtros, para a região da voçoroca. Para o filtro ATIN, que gerou o melhor resultado, foram usados os seguintes parâmetros:

- Tamanho da célula (*cell size*): 1,0;
- Diferença em Z (*Z difference*): 0,2;
- Limiar para ângulo (*angle threshold*): 0;
- Tamanho da grade inicial (*init grid size*): 100;
- Largura X do retângulo (*tile X width*): 200;
- Largura Y do retângulo (*tile Y width*): 200, e
- Tamanho do buffer (*tile buffer*): 200.

A figura 29 ilustra o MDT gerado a partir do MDS. É possível perceber que a filtragem dos dados não eliminou completamente as árvores (ilustradas com um círculo vermelho na figura 28 e um círculo verde na figura 29), formando feições triangulares no nível do terreno. Entretanto, para o entorno da voçoroca, a filtragem modelou a superfície desnuda do terreno e, por isso, o resultado obtido com o filtro ATIN foi adotado para a continuidade dos processamentos.

O MDSN (figura 30), gerado a partir do MDS e do MDT, forneceu informações relativas às alturas, mais úteis que as altitudes na discriminação de feições. Um exemplo é a possibilidade de classificação da vegetação em subclasses como arbórea e rasteira, em função das alturas dos objetos. Como a cena selecionada para o estudo encontra-se em ambiente rural, o MDSN destacou pelas alturas os objetos correspondentes às árvores.






FIGURA 28 – MDTs OBTIDOS COM DIFERENTES FILTROS - ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)



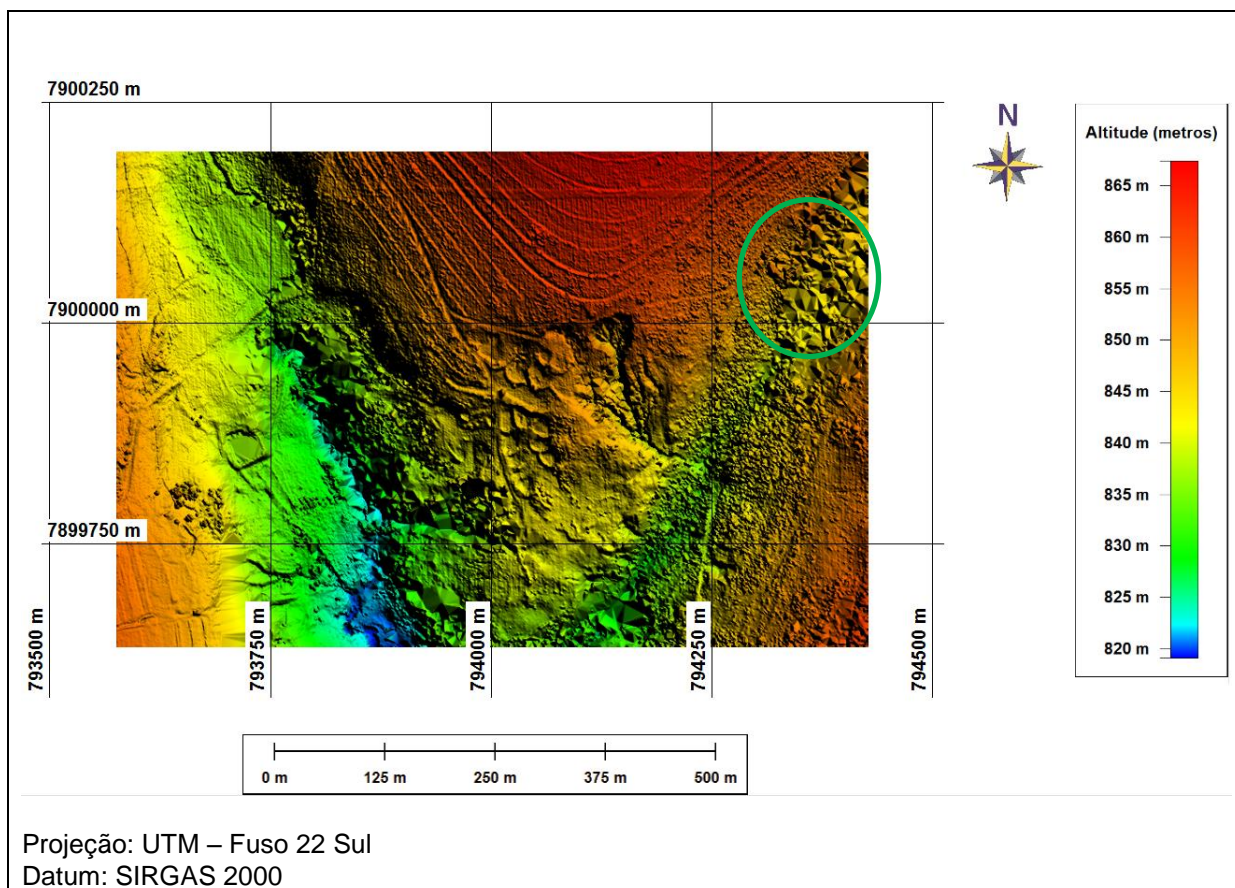


FIGURA 29 – MODELO DIGITAL DE TERRENO DA ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

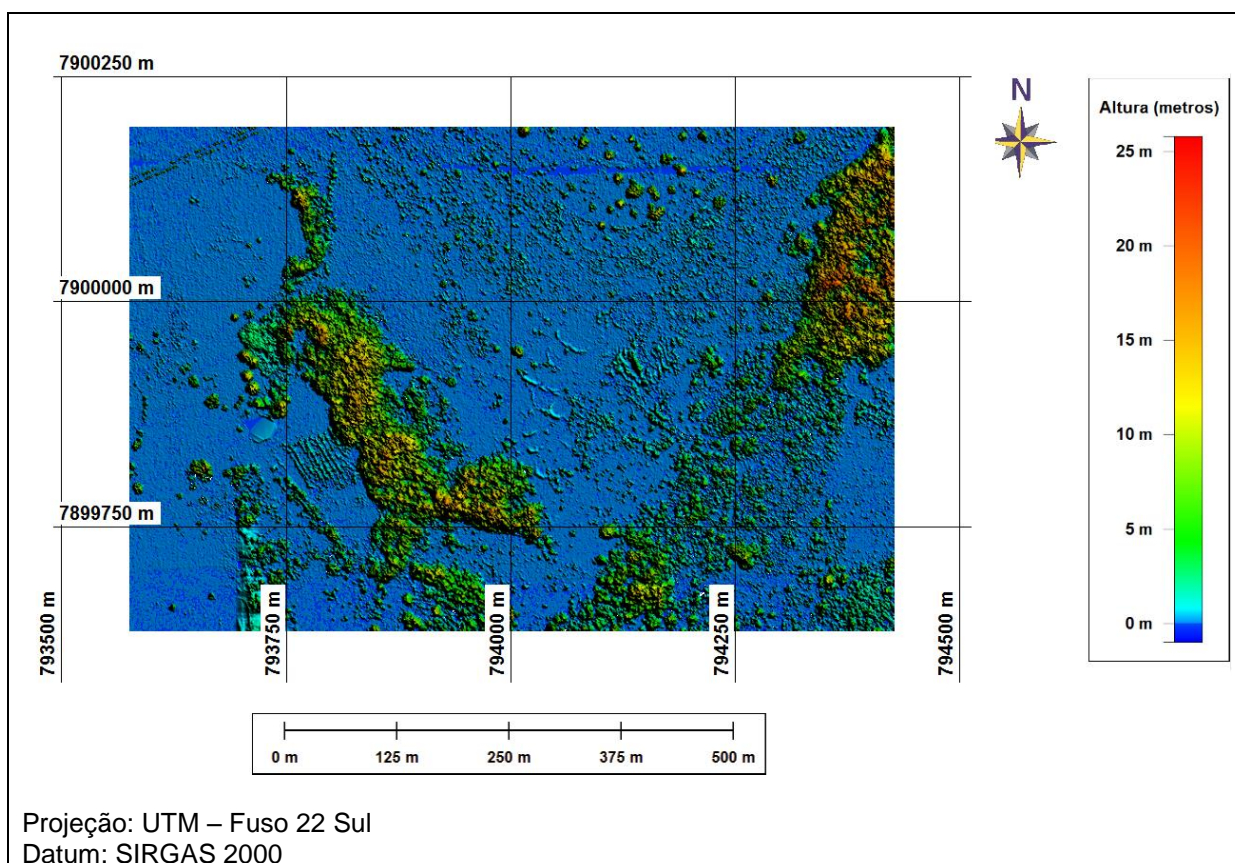


FIGURA 30 – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO DA ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)

Observando-se o MDT, se verificou que na borda externa da cabeceira da voçoroca as altitudes têm valores em torno de 857 m a 855 m e no interior da mesma os valores estão no intervalo de 856 m a 847 m. Como há uma variação brusca nos valores das altitudes nas bordas da cabeceira e dos canais principais e secundários, a informação da declividade constitui um importante elemento discriminante do objeto voçoroca. Em função disso, com as informações do MDT gerou-se o mapa de curvas de nível e, a partir deste, o mapa de declividade. A figura 31 ilustra o mapa de curvas de nível e a figura 32 ilustra o mapa de declividade. Como o MDT apresentou algumas árvores após a filtragem, no mapa de declividade aparecem áreas de alta declividade em torno das mesmas, devido à diferença de altura da copa das árvores para o terreno, e no mapa de curvas de nível foram geradas curvas no entorno das áreas florestadas que não foram filtradas.

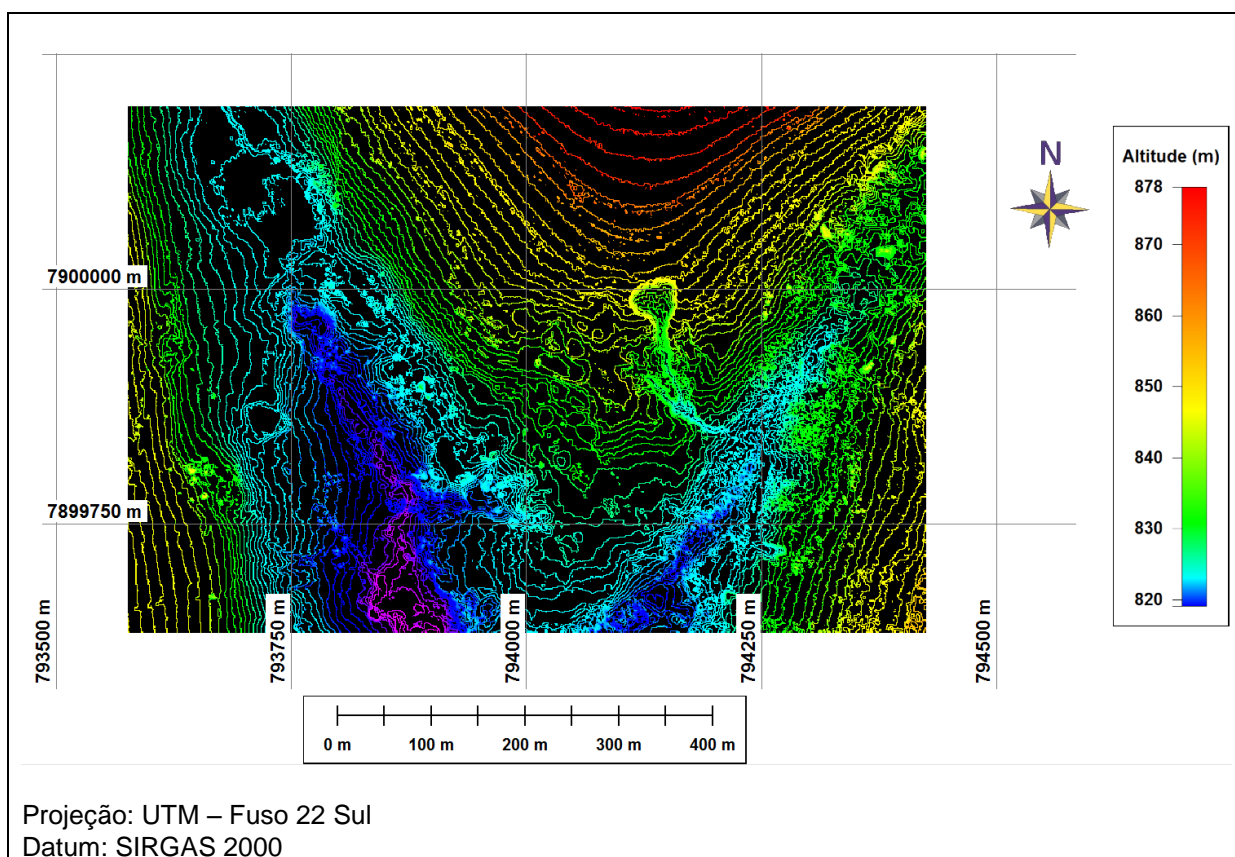


FIGURA 31 – MAPA DE CURVAS DE NÍVEL DA ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)

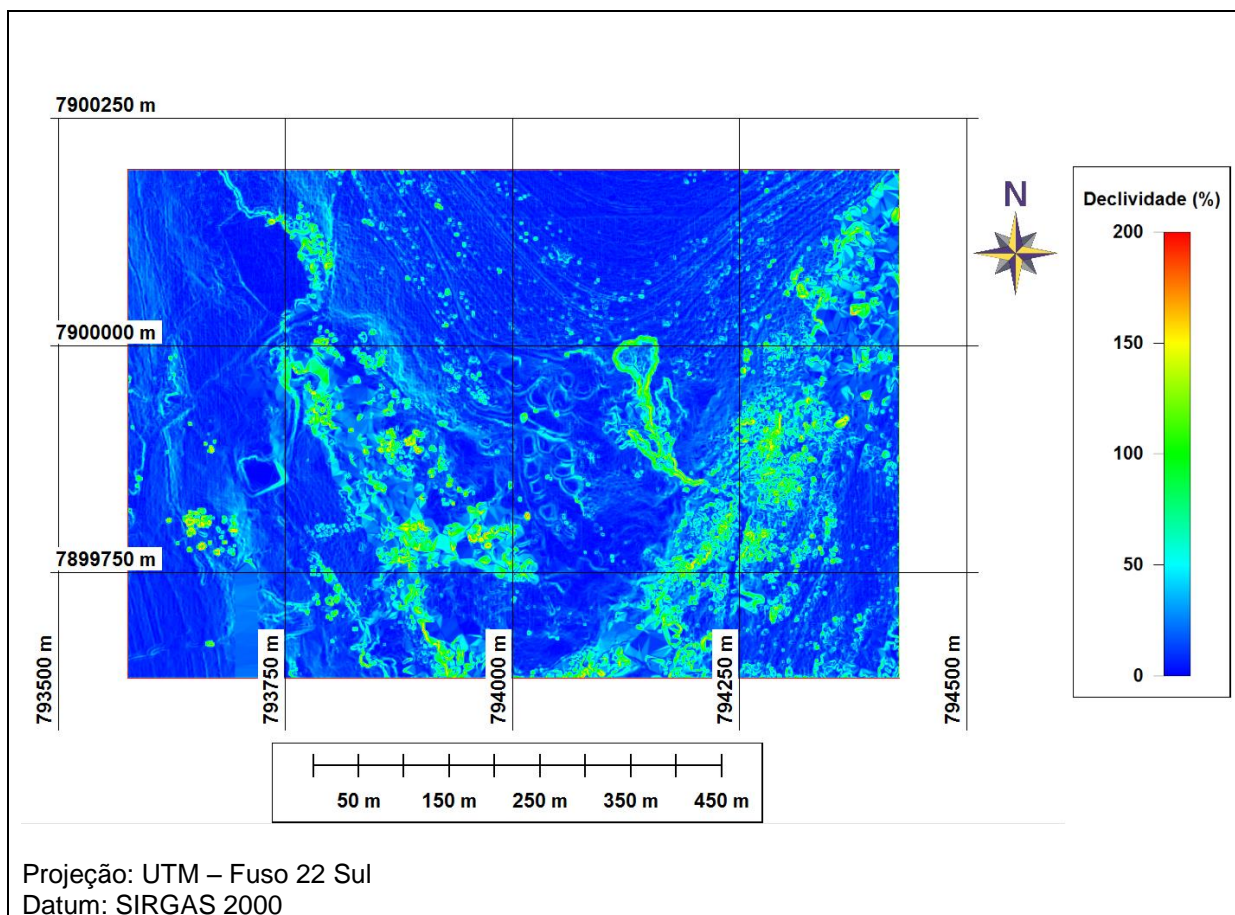



FIGURA 32 – MAPA DE DECLIVIDADE DA ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

A imagem do NDVI, gerada a partir dos dados espectrais, é ilustrada na figura 33. Pode-se perceber que as áreas de vegetação são perfeitamente discriminadas com a informação proveniente dessa imagem e, inclusive, é possível discriminar a vegetação arbórea da rasteira.

## 5.2 PROCESSAMENTO DA NUVEM DE PONTOS ALS DA ÁREA DE ESTUDO A2

A imagem de intensidade (figura 34) apresenta os valores digitais de intensidade no intervalo de 9 (pixels relativos à copa das árvores) a 270 (pixels relativos a solo exposto seco, nas estradas vicinais). O valor máximo é de 394.






Projeção: UTM – Fuso 22 Sul

Datum: SIRGAS 2000

FIGURA 33 – IMAGEM NDVI DA ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)



Projeção: Map Grid of Australia - Fuso 55 Sul

Datum: Australian Geodetic 1994 – GDA94

FIGURA 34 – IMAGEM DE INTENSIDADE DA ÁREA DE ESTUDO A2

FONTE: A AUTORA (2015)

A figura 35 ilustra o MDS. Na região onde se localiza a área de estudo A2 as altitudes variam de 113,21 m a 160,38 m. A região a noroeste apresenta as maiores altitudes e o declive do terreno se dá em direção ao rio, passando pela área da voçoroca. Nessa vertente, existem diversas árvores isoladas e pouca vegetação recobrindo o solo, o que acentua o escoamento superficial, agravando os processos erosivos. Percebe-se também a quase inexistência de mata ciliar. A figura 36 ilustra o MDT gerado a partir dos valores mínimos do último retorno. Os valores estão compreendidos no intervalo de 113,12 m a 158,50 m.

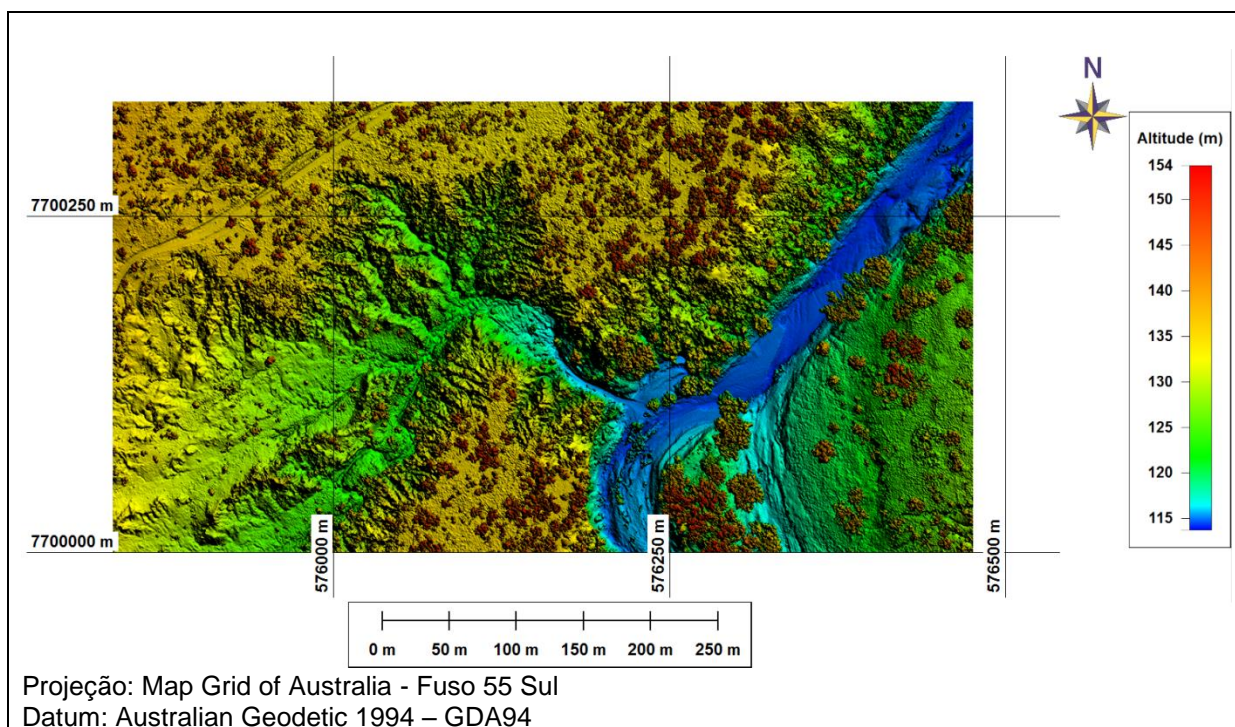


FIGURA 35 – MODELO DIGITAL DE SUPERFÍCIE DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

O MDSN, gerado a partir do MDS e do MDT, é apresentado na figura 37. Como a cena selecionada para o estudo encontra-se em ambiente rural, o MDSN destacou pelas alturas os objetos correspondentes às árvores, assim como para a área de estudo A1. Os valores estão compreendidos no intervalo de 0,0 m a 33,20 m.



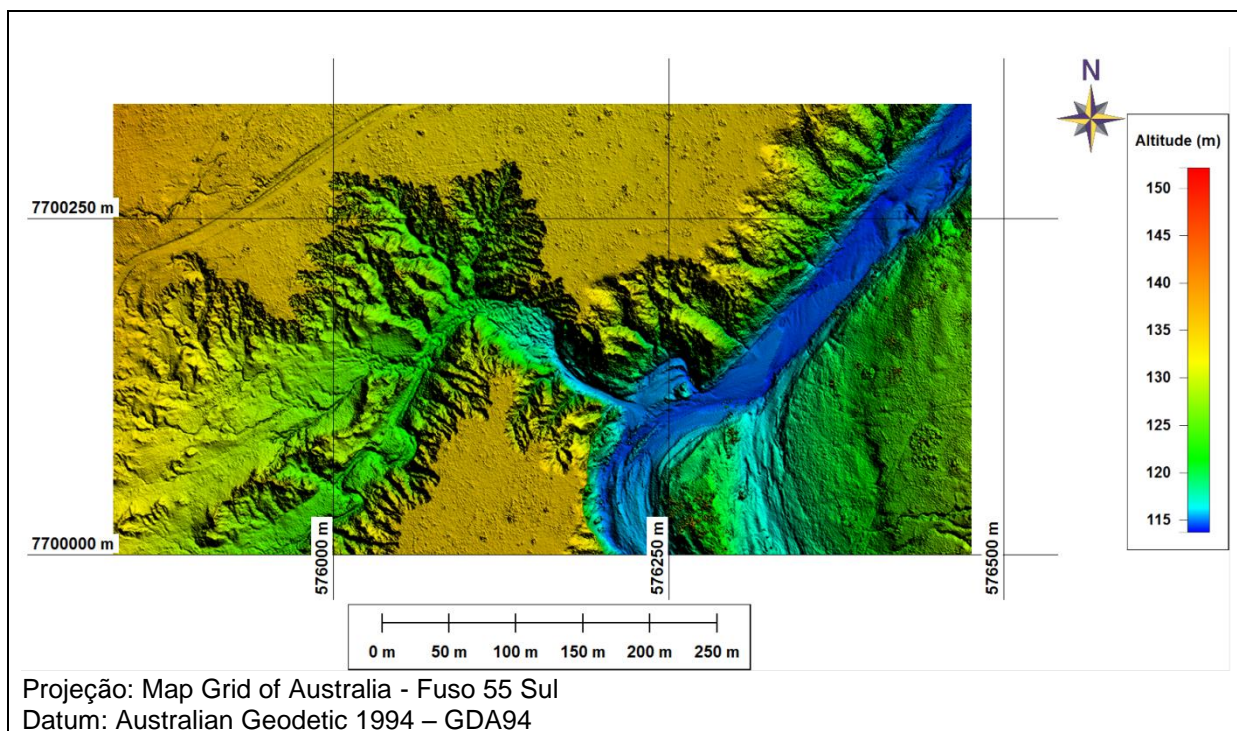


FIGURA 36 – MODELO DIGITAL DE TERRENO DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)




FIGURA 37 – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

A figura 38 ilustra o mapa de curvas de nível e a figura 39 ilustra o mapa de declividade. Em função de MDT apresentar algumas árvores após a filtragem, no

mapa de declividade aparecem áreas de alta declividade em torno das mesmas, em função da diferença de altura da copa das árvores para o nível do terreno.

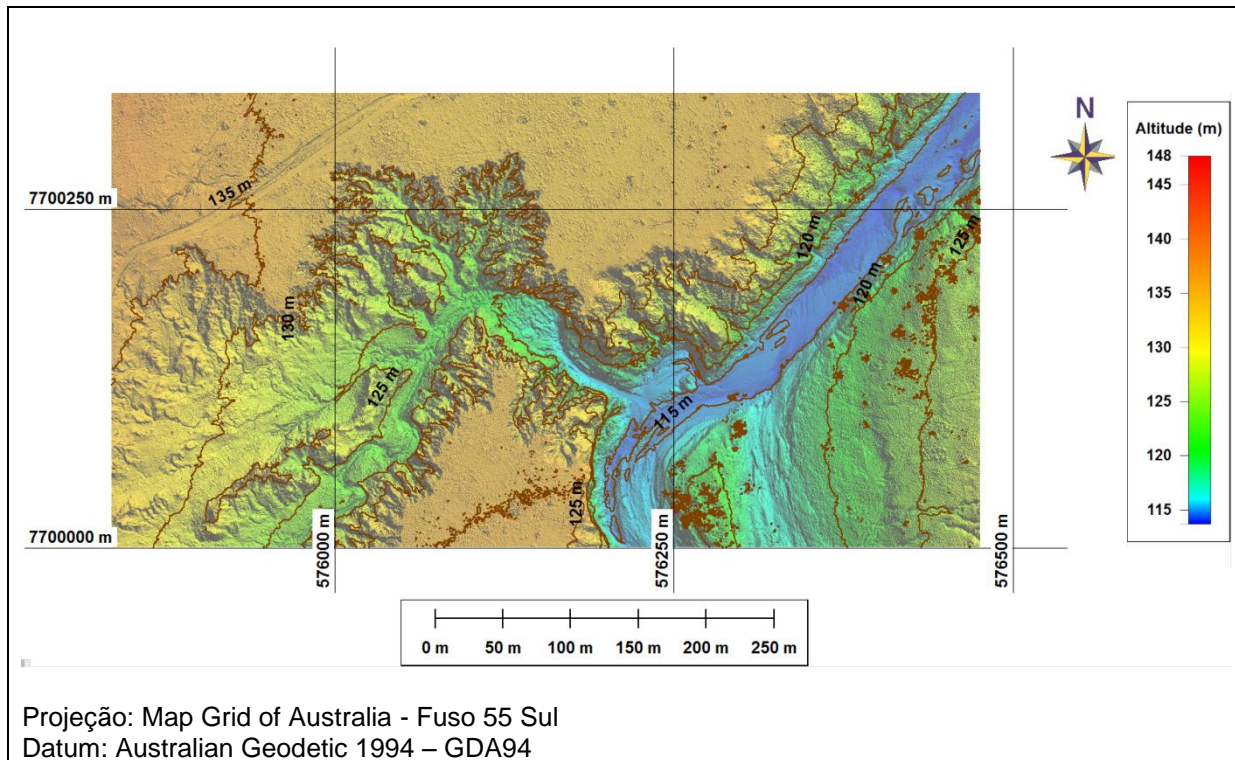


FIGURA 38 – MAPA DE CURVAS DE NÍVEL DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

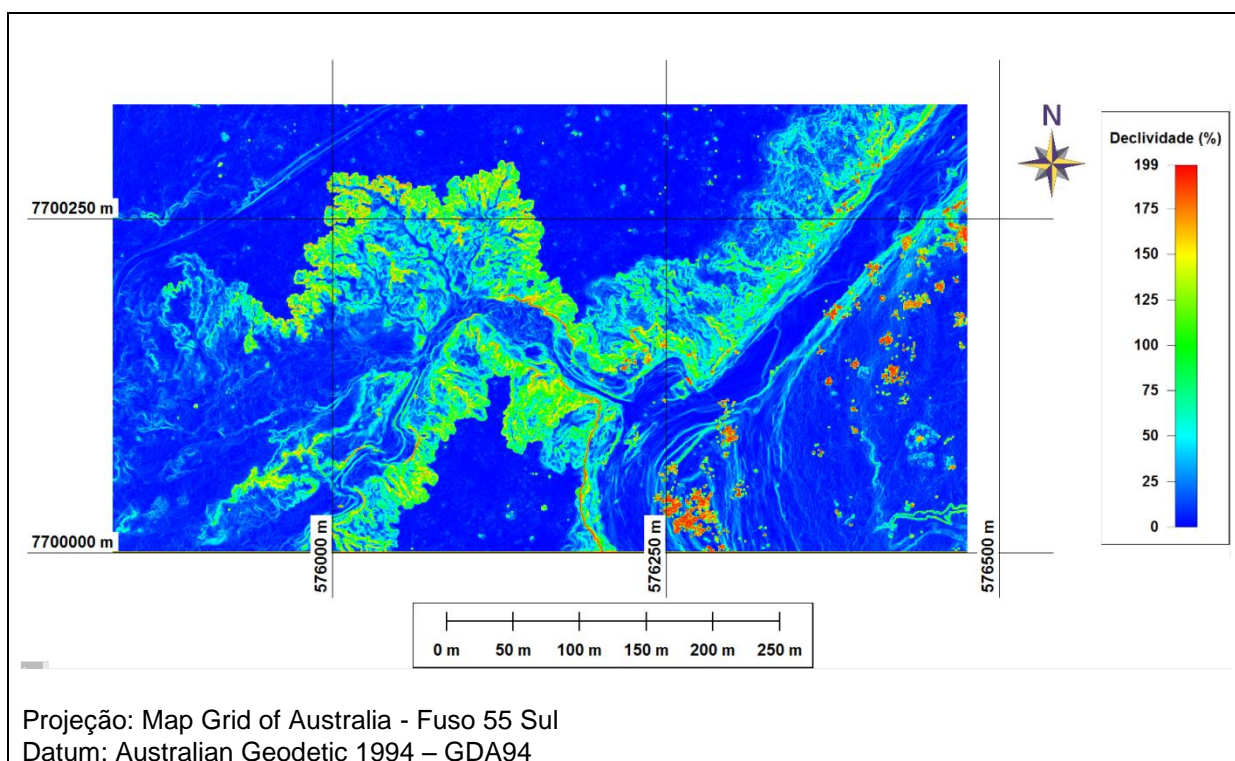


FIGURA 39 – MAPA DE DECLIVIDADE DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)



A figura 40 mostra a imagem correspondente ao Índice de Contraste Baseado na Imagem de Intensidade (ICBI). Os valores encontram-se no intervalo de -1 a +0,91 (similar ao intervalo obtido com NDVI, de -1 a +1). A vegetação arbórea apresenta valores superiores a 0,5, o solo exposto, assim como a vegetação rasteira, apresenta valores entre 0 e 0,5, e as demais feições apresentam valores inferiores a 0. O resultado mostra que o índice proposto permite discriminar as áreas de solo exposto.




FIGURA 40 – IMAGEM ICBI DA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

A título de comparação, foi gerada a imagem ICBI para a área de estudo A1 (figura 41). O solo apresenta valores superiores a 0,0, sendo bastante evidenciado. As áreas com vegetação rasteira apresentam valores inferiores a 0,0. Isso comprova a possibilidade do uso do ICBI na discriminação entre estas duas classes.



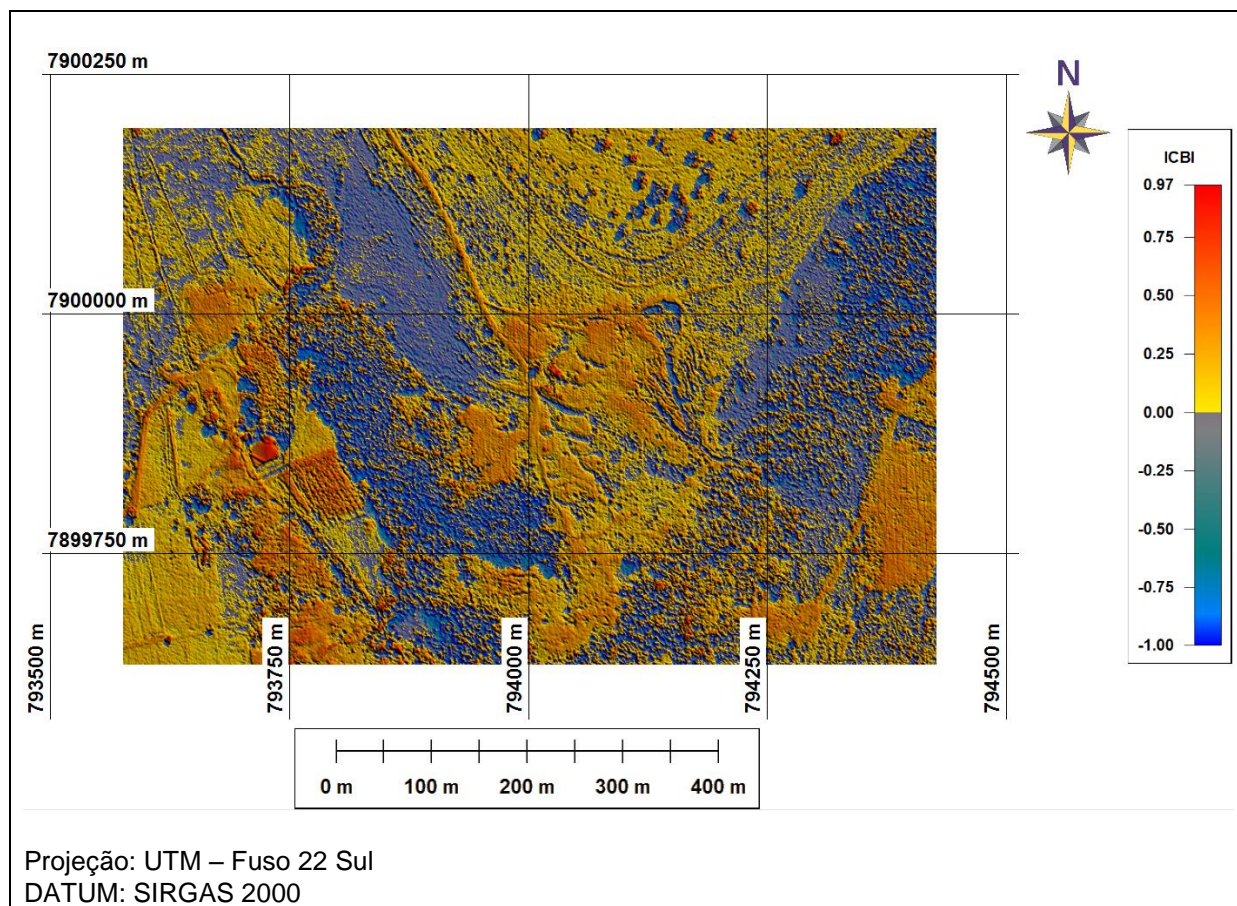


FIGURA 41– IMAGEM ICBI DA ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)

### 5.3 REGISTRO DOS DADOS ESPECTRAIS E ALTIMÉTRICOS DA ÁREA DE ESTUDO A1

O registro da imagem Ikonos em relação à imagem de intensidade foi realizado com base na seleção de dez pontos de controle. Os erros obtidos foram inferiores a dois pixels. O erro máximo em X ( $E_x$ ) foi de 0,8653m, o erro máximo em y ( $E_y$ ) foi de -1,3139m e o erro total foi de 0,869848m, inferior a um pixel.

A distribuição dos pontos não foi homogênea, em virtude de tratar-se de ambiente rural no qual se torna difícil encontrar pontos homólogos. Vale ressaltar que as características espectrais de uma imagem de intensidade, bem como as bordas dos objetos, são diferentes das de uma imagem no espectro óptico, o que dificulta a seleção de pontos homólogos identificáveis em ambas as imagens.

Para a validação do registro, foram selecionados 12 pontos de verificação. Para 3 pontos (25% do total) obteve-se erro superior a 2 pixels (igual a 3). Para 75% do conjunto de dados obteve-se erro igual ou inferior a 2 pixels. Detalhes sobre o georreferenciamento podem ser encontrados no apêndice.

#### 5.4 GERAÇÃO DE OBJETOS

O primeiro nível de segmentação, com  $FE=5$ , não permite a distinção de quaisquer objetos, mas origina objetos-primitivos semelhantes aos pixels. A partir destes, os objetos vão sendo agregados, em função de suas semelhanças nos dados usados como entrada no processamento. A escolha do nível em que será realizada a classificação é dependente dos alvos de interesse. Para a classificação por árvores de decisão, apenas um nível pode ser usado. Para a classificação hierárquica, são selecionados os níveis adequados à discriminação de cada classe, de forma independente.

No procedimento de mineração dos dados, para ambas as áreas de estudo, foram usados os objetos resultantes da segmentação com  $FE=50$ . As figuras 42 e 43 ilustram os objetos obtidos para as áreas de estudo A1 e A2, respectivamente. Na imagem “a” das figuras, os objetos estão superpostos a uma pré-classificação efetuada automaticamente pelo programa utilizado. Na imagem “b” os objetos estão superpostos às imagens originais em composição colorida (bandas do visível em R=red; G=green; B= blue). Para a área de estudo A1, pode-se perceber que, devido à pouca mistura espectral entre os objetos, na pré-classificação os mesmos já podem ser discriminados de forma bastante semelhante à imagem original. O mesmo não acontece para a área A2, em virtude da heterogeneidade e dispersão espacial dos objetos constituintes da cena, principalmente árvores isoladas. Essa análise, mesmo que qualitativa, já permite antever as possíveis dificuldades que serão encontradas no procedimento de classificação.

Para A1, no nível com  $FE=50$ , é possível delinear o contorno das feições da

cabeceira e dígitos (canais secundários e mais estreitos) da voçoroca, bem como distinguir áreas de vegetação arbórea e rasteira, mesmo para árvores isoladas. Áreas de solo exposto e de sombra também são distinguíveis. O contorno da estrada é bem delineado neste nível.

Para a área de estudo A2, os objetos constituintes da cabeceira da voçoroca, as áreas de solo exposto, de sombra e de vegetação podem ser diferenciadas no nível com FE=50.

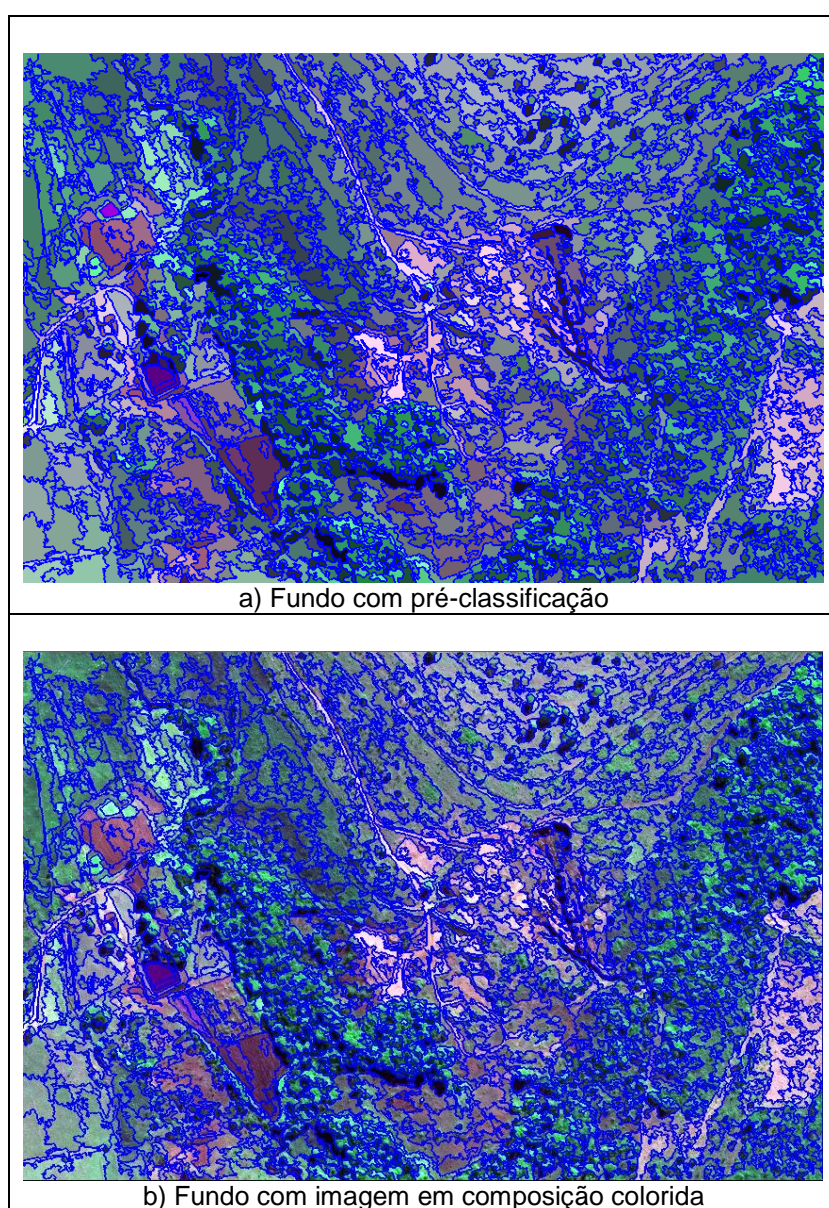


FIGURA 42 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=50 PARA ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)






FIGURA 43 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=50 PARA ÁREA DE ESTUDO A2

FONTE: A AUTORA (2015)

De forma a comparar os objetos resultantes de segmentações com diferentes fatores de escala, e evidenciar as razões da escolha do FE=50 como referência, são apresentados os objetos obtidos com FE=100, nas figuras 44 e 45 (para as áreas de estudo A1 e A2, respectivamente).

Para A1, no nível com FE=100, devido à junção de muitos objetos, não é possível delinear os dígitos da voçoroca (feições estreitas), pois esses elementos estão agregados com objetos de solo exposto. Entretanto, nesse nível podem-se



separar as áreas vegetadas e não vegetadas.

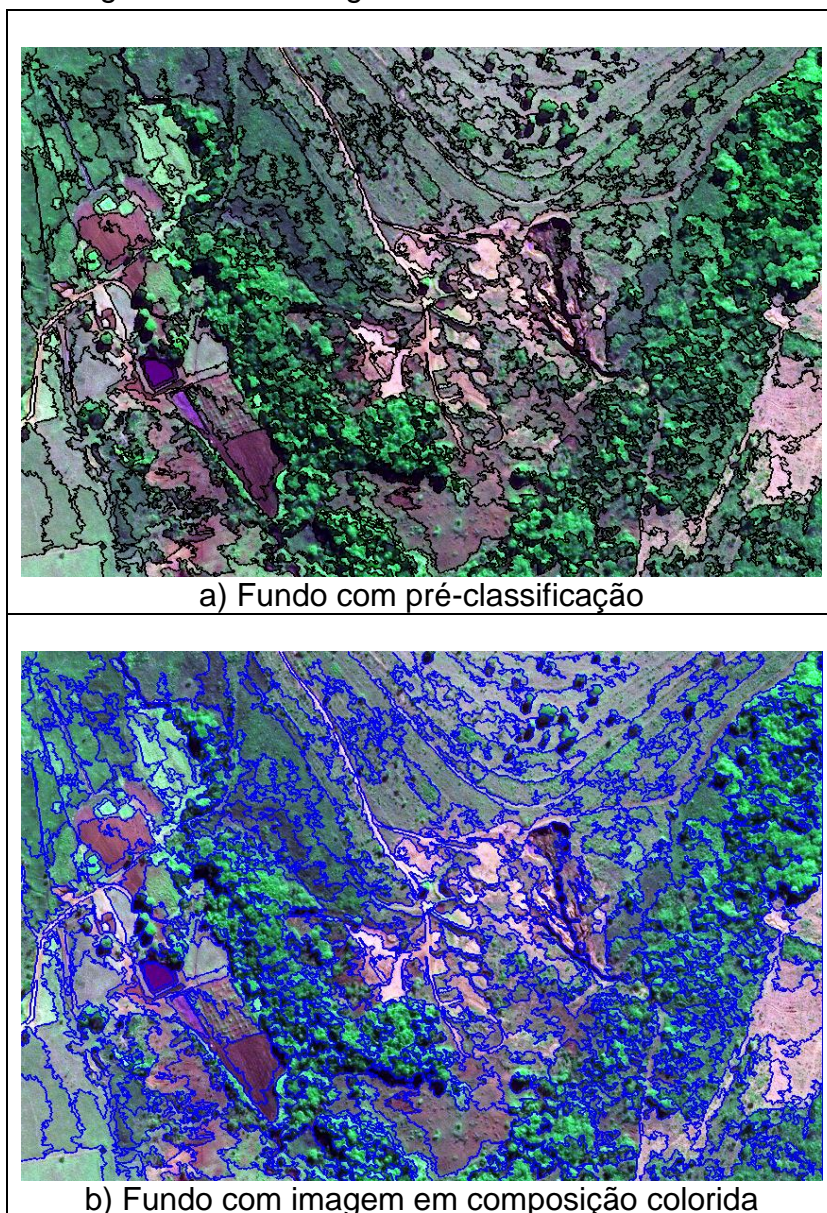


FIGURA 44 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=100 PARA ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)

Para A2, não é possível distinguir nesse nível os objetos constituintes da voçoroca, visto que os mesmos foram agregados com objetos de solo exposto e de sombra. Árvores isoladas também não são distinguíveis nesse nível, pois são muito pequenas (diâmetro em torno de 1 metro) em relação ao fator de escala selecionado.




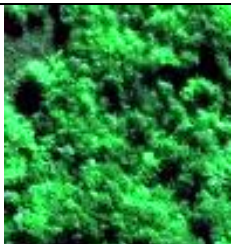




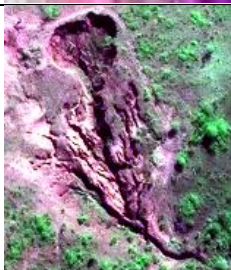


FIGURA 45 – OBJETOS PROVENIENTES DA SEGMENTAÇÃO COM FE=100 PARA ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

## 5.5 PLANEJAMENTO DA CLASSIFICAÇÃO

Antes de todo processo de criação de classes baseado em hierarquia de objetos segmentados (subobjetos e superobjetos), é necessária uma criteriosa avaliação do comportamento espectral e de forma das feições. Isto só é atingido com o conhecimento do usuário sobre o tema. O quadro 7 mostra as chaves de interpretação para a área de estudo A1, para uma composição colorida R=banda 3, G=banda 4 e B=banda 1.

<b>Classe</b>	<b>Amostra</b>	<b>Cor</b>	<b>Forma, tamanho, textura, var. altura</b>
Vegetação arbórea		Verde (variando de tons escuros a médios)	Formas irregulares e tamanhos variados devido à presença tanto de árvores isoladas quanto agrupadas; textura rugosa; variação de altura.
Vegetação Rasteira		Verde (variando de tons escuros a claros)	Formas regulares quase retangulares; tamanhos de médio a grande; textura lisa; sem variação de altura.
Solo exposto Seco		Branco a rosa	Formas irregulares; tamanhos variando de médio a grande; textura lisa; sem variação de altura.
Solo exposto Úmido		Roxo	
Corpos d'água		Azul	Formas regulares; tamanho médio; textura lisa; sem variação de altura
Voçoroca		Mistura de solo / vegetação e sombra (rosa, roxo, verde, preto)	Formas irregulares; tamanhos variando de pequenos a médios, devido à presença diferentes feições (cabeceira, canal e dígitos); textura rugosa; variação de altura.





QUADRO 7 - CHAVES DE INTERPRETAÇÃO – ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)

OBS: COMPOSIÇÃO COLORIDA R=3, G=4, B=1

Por se tratar de ambiente rural, poucas classes foram identificadas para o interesse desse estudo, as quais são: vegetação arbórea, vegetação rasteira, solo exposto, corpos d'água e voçoroca. O quadro 8 mostra as chaves de interpretação

para a área de estudo A2, para uma composição colorida R=red, G=green e B=blue. Foram definidas as classes: vegetação, solo exposto, sombra e voçoroca.

<b>Classe</b>	<b>Amostra</b>	<b>Cor</b>	<b>Forma, tamanho, textura, var. altura</b>
Vegetação		Verde (variando de tons escuros a médios)	Formas irregulares e tamanhos variados devido à presença tanto de árvores isoladas quanto agrupadas; textura rugosa; variação de altura.
Solo exposto		Roxo, rosa, branco, marrom claro e escuro	Formas irregulares e tamanhos variados. Textura lisa.
Sombra		Preto	Formas irregulares e tamanhos variados, pois estão no entorno de árvores aglomeradas e isoladas, e da voçoroca.
Voçoroca		Mistura de solo / vegetação e sombra (branco, verde, preto)	Formas irregulares; tamanhos variando de pequenos a médios, devido à presença de diferentes feições, em diferentes estágios de evolução; textura rugosa; variação de altura, alta declividade nas bordas.

QUADRO 8 - CHAVES DE INTERPRETAÇÃO – ÁREA DE ESTUDO A2

FONTE: A AUTORA (2015)

OBS: COMPOSIÇÃO COLORIDA R=RED, G=GREEN, B=BLUE



## 5.6 MINERAÇÃO DE DADOS

### - ÁREA DE ESTUDO A1:

A figura 46 ilustra as amostras selecionadas para o treinamento da árvore de decisão correspondente à área A1. Buscou-se selecionar amostras abrangendo todo o intervalo de valores possíveis para cada classe, em cada banda.




FIGURA 46 – AMOSTRAS PARA TREINAMENTO DA ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1

FONTE: A AUTORA (2015)

A figura 47 mostra a árvore de decisão obtida para a área de estudo A1. A árvore sugere uma primeira divisão que resulta no nó-folha para a classe vegetação arbórea e no nó intermediário 1. Essa divisão foi realizada pelo atributo de Média Circular para o MDSN. No nó intermediário 1 a divisão resulta no nó-folha para a classe água e no nó intermediário 2. Essa divisão foi realizada pelo atributo de Média Circular para o NDVI. No nó intermediário 2 a divisão resulta em dois nós intermediários 3 e 4, divididos pelo atributo NDVI. No nó 3, usando o atributo de Média Circular para a declividade, surgem dois nós folhas para as classes solo exposto e voçoroca. No nó 4, usando o atributo Brilho, surgem dois nós folhas para

as classes sombra e vegetação rasteira. A árvore resultante tem profundidade igual a 4.

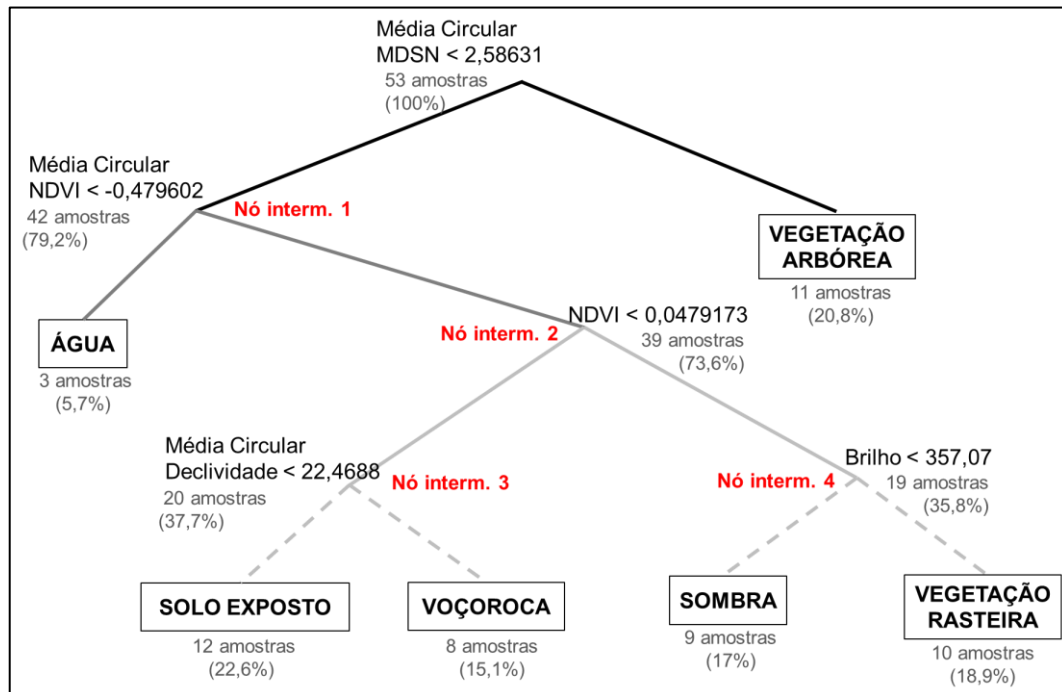


FIGURA 47 - ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

A figura 48 apresenta as imagens relativas aos atributos selecionados pela árvore de decisão. Pode-se verificar a efetividade da discriminação entre as classes sugeridas pela árvore em cada nó, em função do atributo selecionado.

A tabela 1 apresenta a matriz de confusão para as amostras de treinamento. Como a árvore de decisão serviu para embasamento da classificação hierárquica, não foi avaliada a matriz de confusão para amostras de verificação, apenas para as amostras de treinamento. Todas as amostras selecionadas foram classificadas corretamente, obtendo-se uma acurácia global igual a 1, bem como o índice de concordância Kappa também igual a 1.

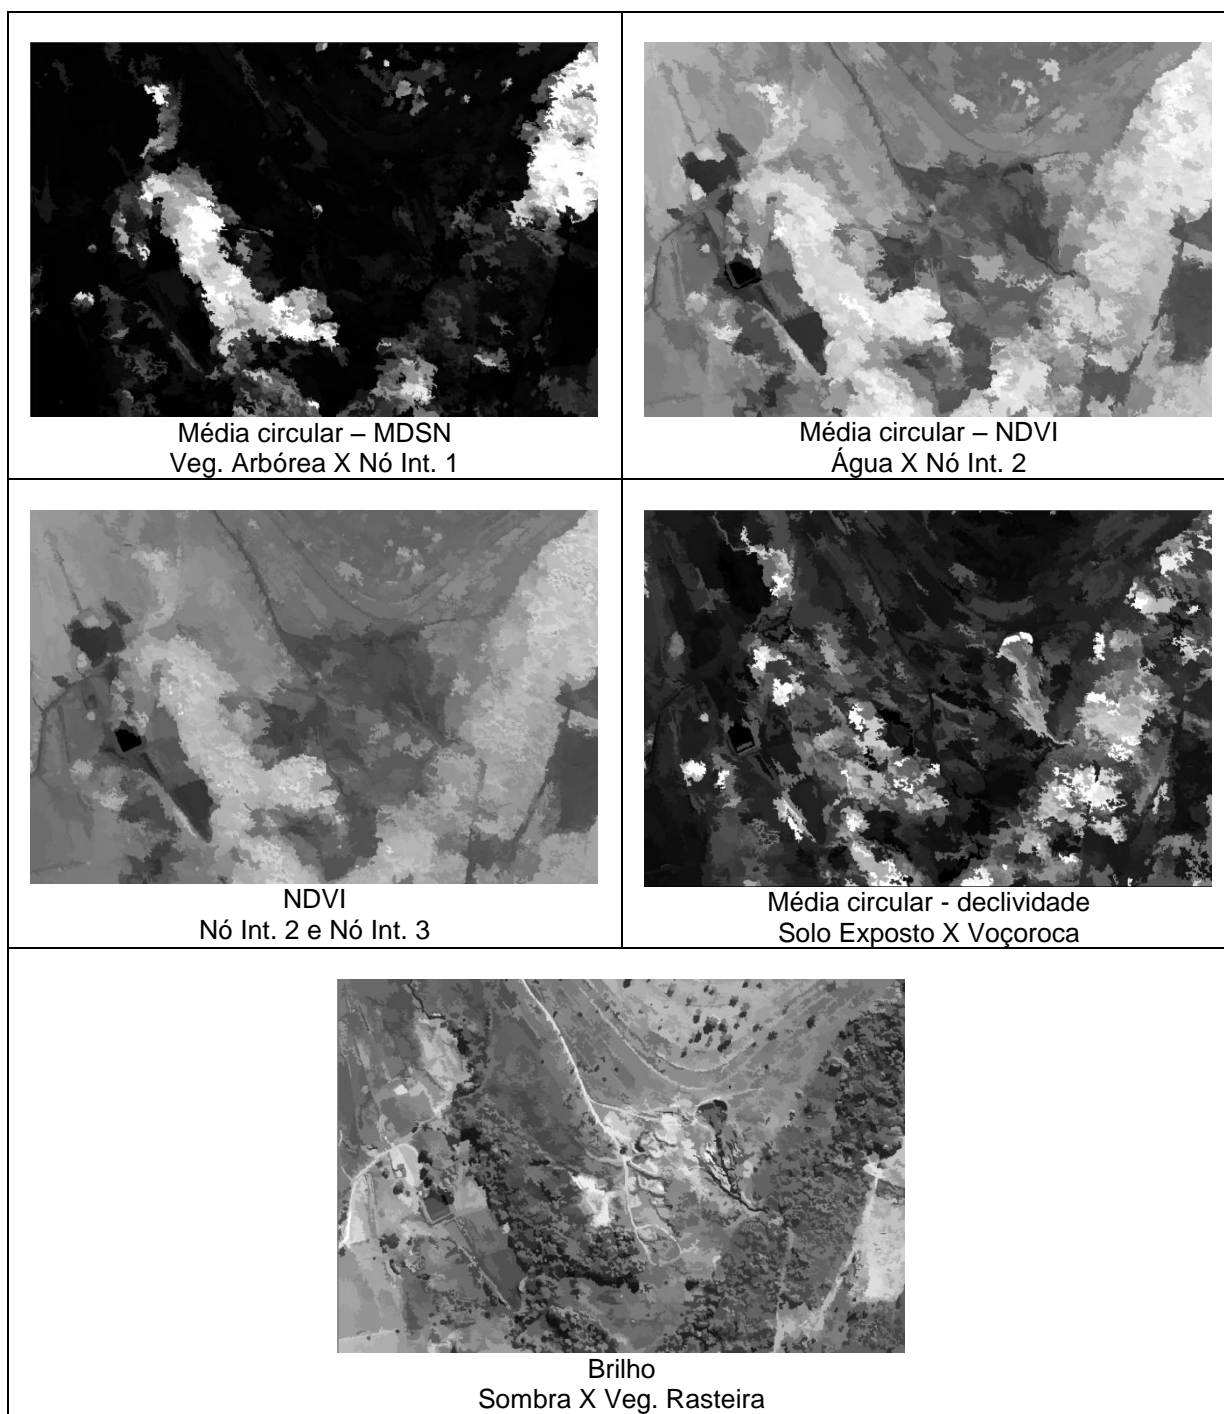


FIGURA 48 – ATRIBUTOS SELECIONADOS NA MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

TABELA 1 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE TREINAMENTO (CLASSIF. POR ÁRVORE DE DECISÃO) – ÁREA DE ESTUDO A1

Classes	Veg. Rast.	Água	Solo Exposto	Veg. Arbórea	Voçoroca	Sombra	Soma	Acurácia usuário
Veg. Rasteira	10	-	-	-	-	-	10	1
Água	-	3	-	-	-	-	3	1
Solo Exposto	-	-	12	-	-	-	12	1
Veg. Arbórea	-	-	-	11	-	-	11	1
Voçoroca	-	-	-	-	8	-	8	1
Sombra	-	-	-	-	-	9	9	1
Soma	10	3	12	11	8	9		
Acurácia produtor	1	1	1	1	1	1		

FONTE: A AUTORA (2015)

A figura 49 apresenta a classificação obtida com a aplicação da árvore de decisão. Pode-se perceber que houve confusão entre as classes voçoroca e solo exposto, tendo sido alguns objetos, de solo exposto, adicionados à classe voçoroca (erro de inclusão), principalmente no entorno do canal principal da voçoroca. No entorno, a classificação errônea pode ser explicada pela alta declividade existente no canal principal, no canal secundário e nos dígito da voçoroca. A matriz de confusão ilustrada na tabela 1 não evidencia a confusão, pois se baseia apenas nas amostras de treinamento. Devido à proximidade desses elementos, os objetos nessa região são influenciados pela resposta de seus vizinhos, sendo incorporados à classe voçoroca. Mesmo com a alta similaridade entre essas duas classes, a classe voçoroca pôde ser discriminada usando atributos relacionados à declividade, evidenciando que a incorporação de dados altimétricos auxilia na classificação de voçorocas, conforme a hipótese sugerida.



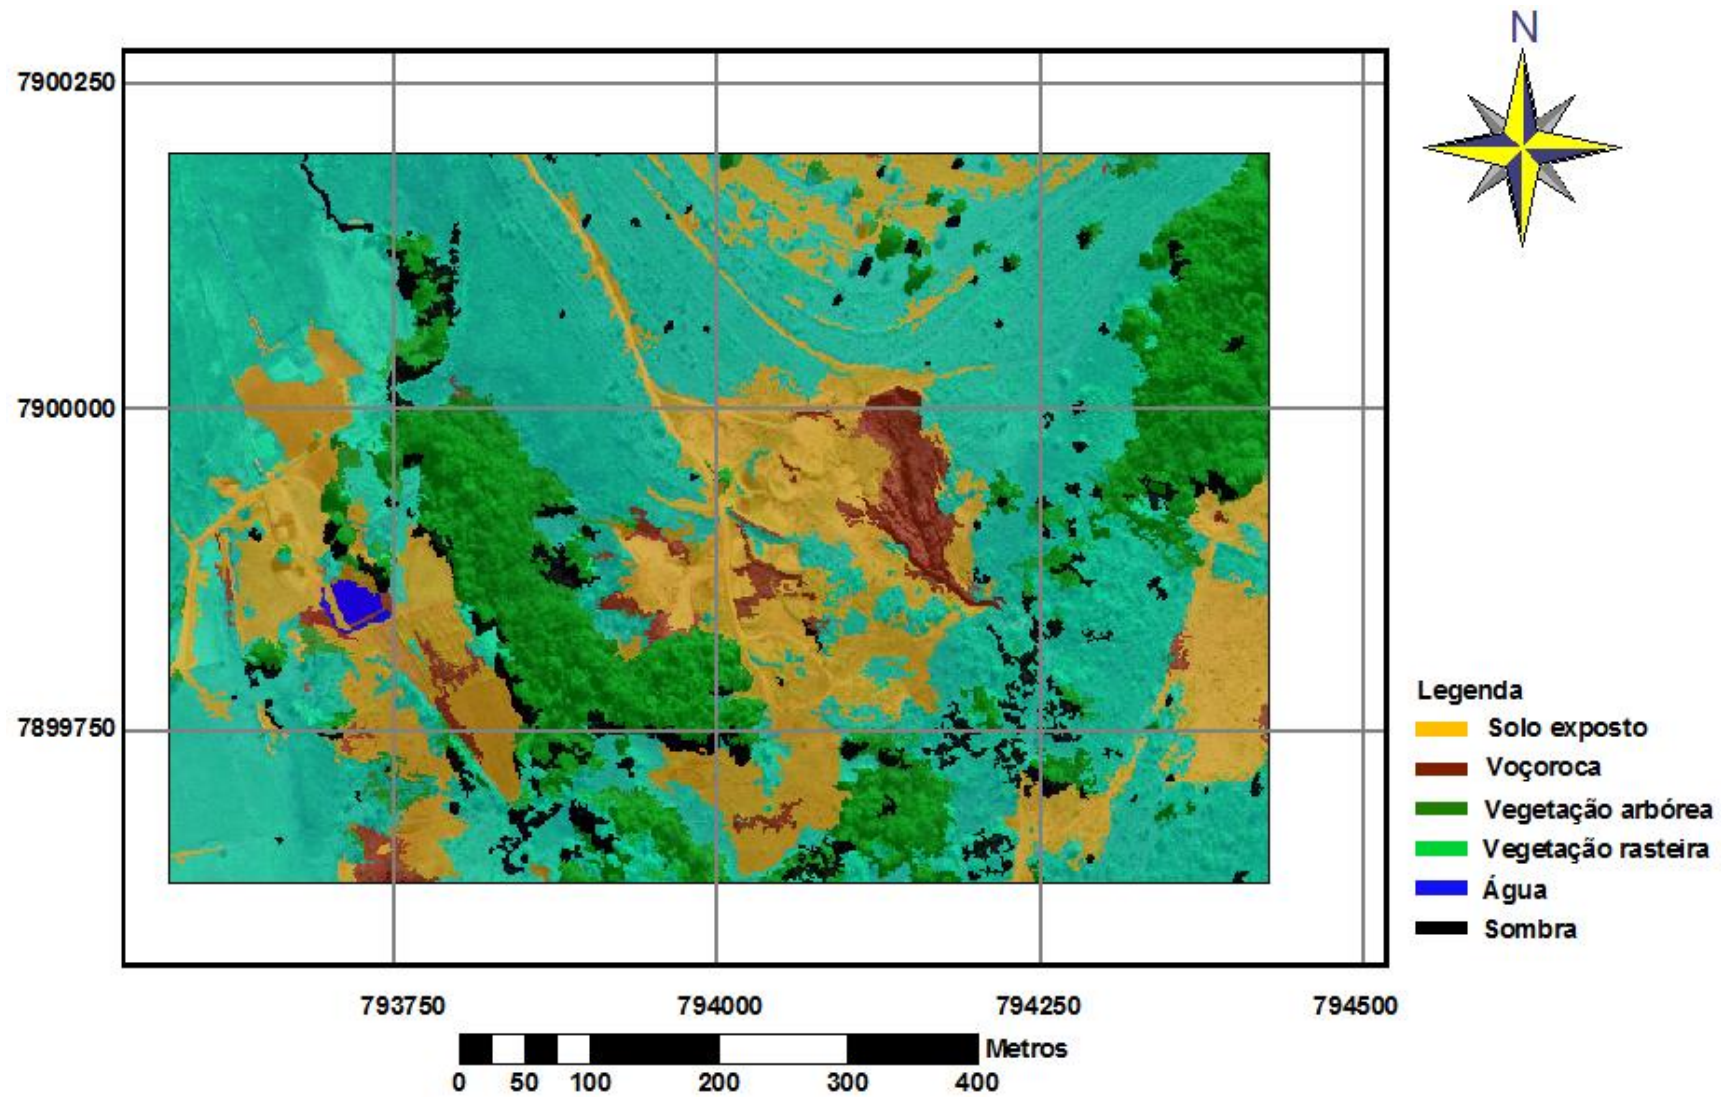


FIGURA 49 – CLASSIFICAÇÃO POR ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

- ÁREA DE ESTUDO A2:

A figura 50 ilustra as amostras selecionadas para o treinamento da árvore de decisão correspondente à área A2 e a figura 51 mostra a árvore de decisão obtida. A árvore sugere uma primeira divisão que resulta no nó-folha para a classe voçoroca e no nó intermediário 1. Essa divisão foi realizada pelo atributo de Textura de Haralick – Entropia GLDV (quick 8/11 para todas as direções, para a imagem de declividade). No nó intermediário 1, a divisão resulta no nó-folha para a classe sombra e no nó intermediário 2. Essa divisão foi realizada usando o atributo relativo à resposta média espectral da banda do verde (green). No nó intermediário 2, a divisão resulta no nó-folha para a classe vegetação e no nó intermediário 3. Essa divisão foi realizada usando o atributo relativo à resposta média espectral da banda do azul (blue). Parte das amostras de vegetação foram classificadas neste nó (7 amostras de um total de 10) e as demais amostras só puderam ser classificadas na próxima divisão da árvore. No nó intermediário 3 a divisão resulta nos nós-folhas para as classes vegetação e solo exposto. Essa divisão foi realizada usando o atributo relativo à Textura de Haralick – Entropia GLDV (para todas as direções, para a imagem de declividade). A árvore resultante tem profundidade igual a 4. A figura 52 apresenta as imagens relativas aos atributos selecionados pela árvore de decisão.



FIGURA 50 - AMOSTRAS PARA TREINAMENTO DA ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2

FONTE: A AUTORA (2015)

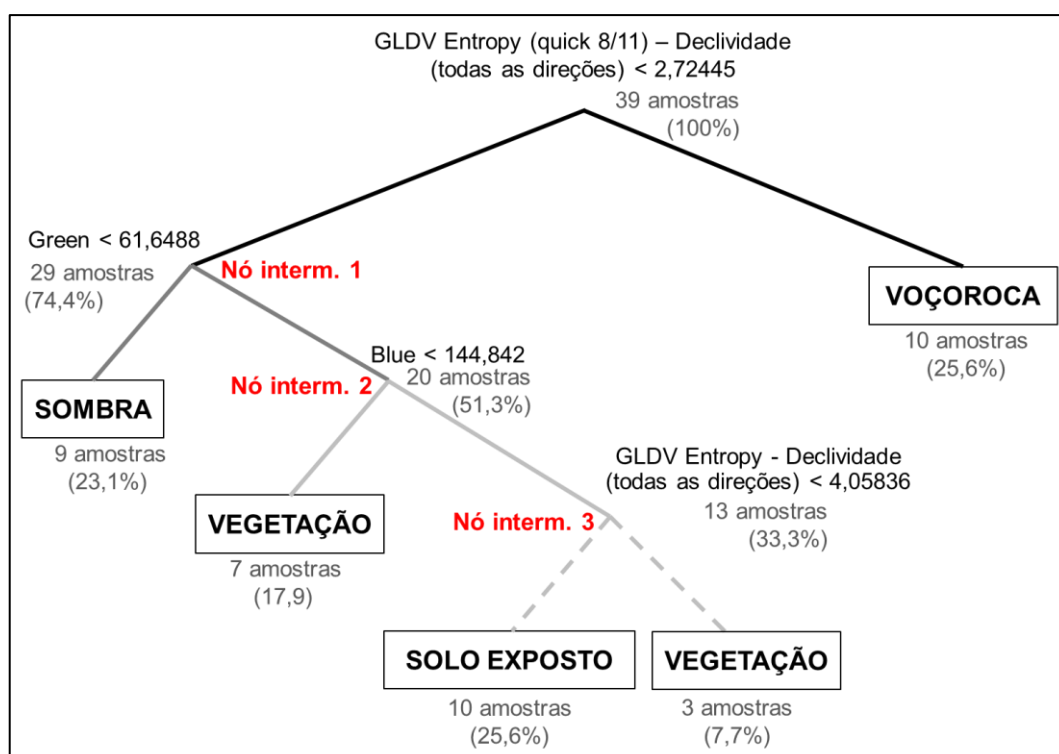


FIGURA 51 - ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2

FONTE: A AUTORA (2015)



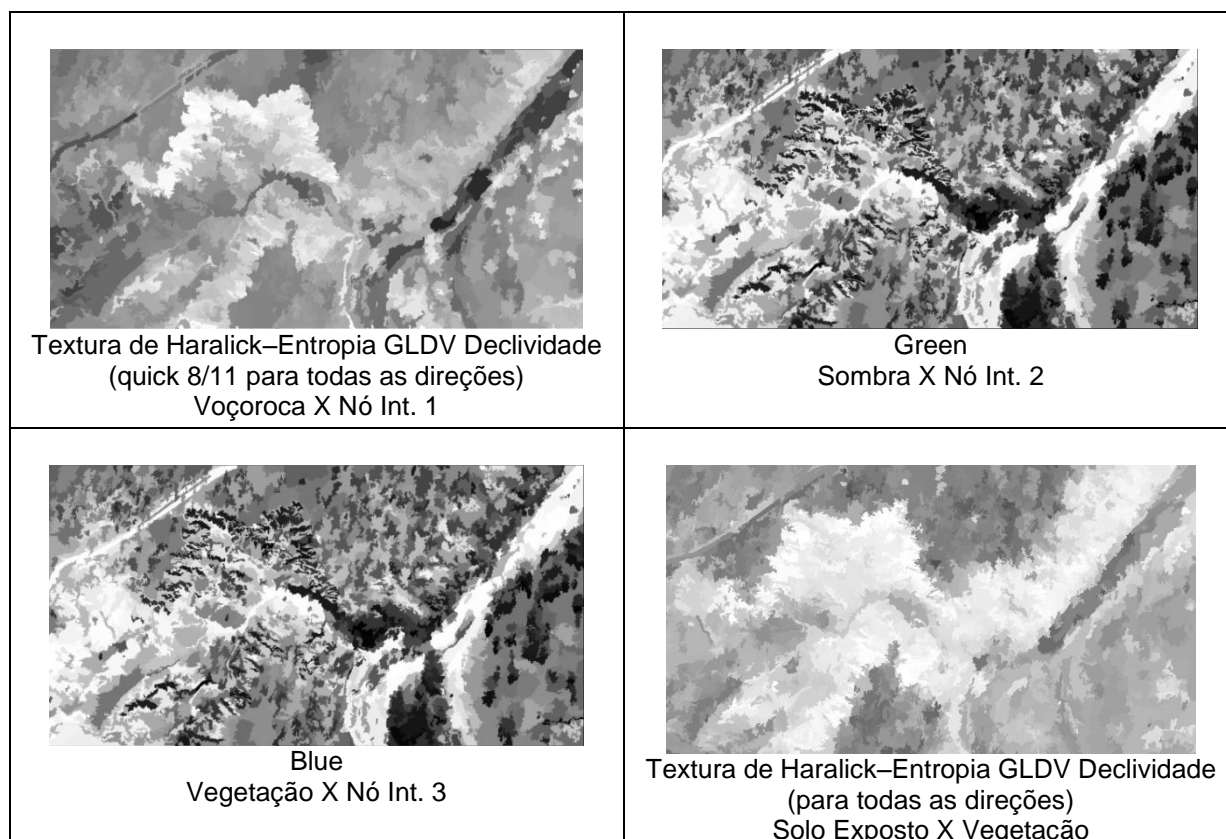


FIGURA 52 – ATRIBUTOS SELECIONADOS NA MINERAÇÃO DE DADOS – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

A figura 53 apresenta a classificação obtida com a aplicação da árvore de decisão. Pode-se perceber que houve confusão entre as classes voçoroca e vegetação, tendo sido alguns objetos de vegetação adicionados à classe voçoroca (erro de inclusão). A classificação errônea pode ser explicada pela diferença de altura entre as copas das árvores e o chão (que gerou declividade acentuada nas bordas das copas), já que o atributo de declividade (usado para cálculo do atributo Entropia GLDV) foi usado para discriminar a classe voçoroca.

Mesmo com a alta similaridade entre as classes solo exposto e voçoroca, esta última pôde ser discriminada usando atributos relacionados à declividade, assim como na área A1. Isso reforça a efetividade da incorporação de dados altimétricos na classificação de voçorocas, conforme verificado também por JOHANSEN *et al.* (2012). A tabela 2 apresenta a matriz de confusão para as amostras de treinamento. Para as amostras selecionadas, a confusão ocorreu apenas entre a classe vegetação e solo exposto, tendo sido incluída uma amostra de vegetação à classe



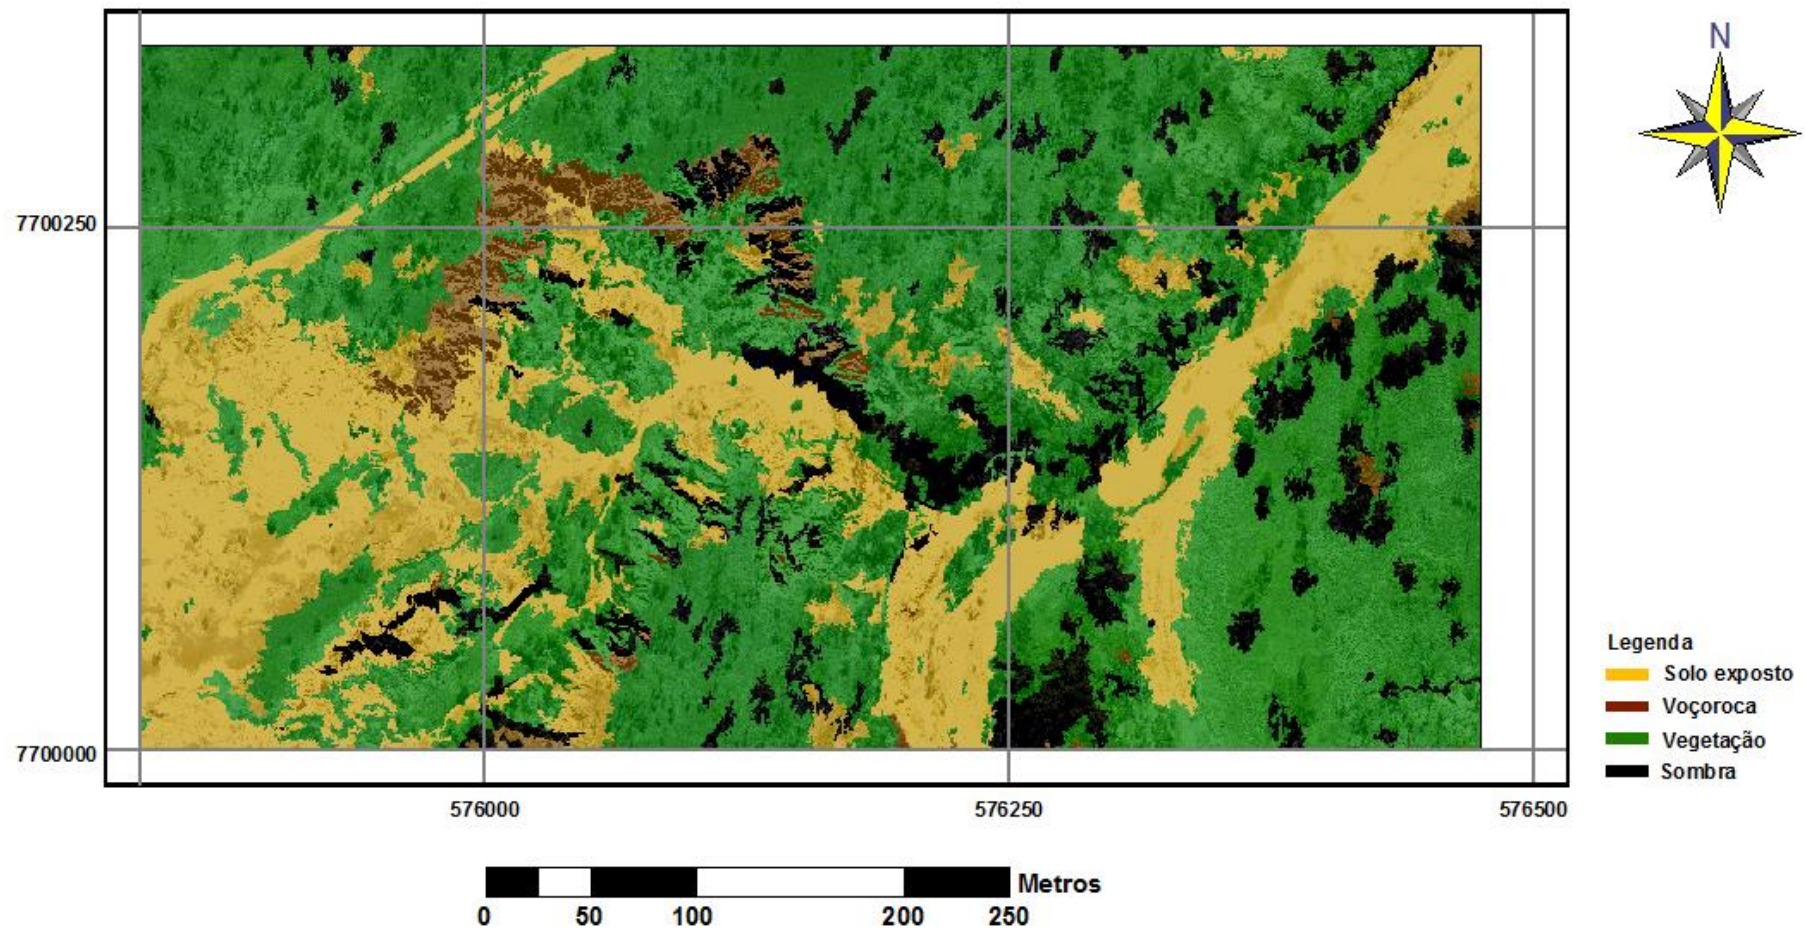


FIGURA 53 – CLASSIFICAÇÃO POR ÁRVORE DE DECISÃO – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

de solo exposto. Isso pode ser explicado devido à vegetação rasteira bastante escassa, que permite entrever o solo. A acurácia global foi igual a 97,44%, e o índice de concordância Kappa igual a 0,9657895.

TABELA 2 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE TREINAMENTO (CLASSIF. POR ÁRVORE DE DECISÃO) – ÁREA DE ESTUDO A2

Classes	Vegetação	Solo Exposto	Sombra	Voçoroca	Soma	Acurácia do usuário
Vegetação	9	1	-	-	10	0,9
Solo Exposto	-	10	-	-	10	1
Sombra	-	-	9	-	9	1
Voçoroca	-	-	-	10	10	1
Soma	9	11	9	10		
Acurácia do produtor	1	0,909	1	1		

FONTE: A AUTORA (2015)

## 5.7 CLASSIFICAÇÃO DE OBJETOS POR MEIO DE LÓGICA FUZZY E HIERARQUIA

A partir das chaves de interpretação, da análise dos atributos e da mineração dos dados, foram definidos os descritores de cada classe, bem como as funções de pertinência Fuzzy, usados na classificação hierárquica. Os descritores foram definidos com base na solução apontada pelas árvores de decisão e de forma empírica, em função da base de conhecimento especialista e na avaliação dos resultados obtidos quando do uso de diferentes descritores. Para algumas classes usou-se apenas o algoritmo classificador do vizinho mais próximo (NN – *nearest neighbour*) e para outras classes foram usadas também funções de pertinência Fuzzy. As etapas para o refinamento da classificação são detalhadas a seguir.

### 5.7.1 Definição da rede hierárquica

A elaboração das redes hierárquicas, para as duas áreas de estudo, se deu em função dos objetos que poderiam ser distinguidos nos diferentes níveis de segmentação. Como as redes hierárquicas são distintas, em função das classes

presentes nas duas cenas, ambas são explanadas separadamente na sequência.

#### - ÁREA DE ESTUDO A1:

A figura 54 ilustra a rede hierárquica para a área de estudo A1. Em um nível mais grosseiro (FE=150), os objetos foram separados em vegetação e não vegetação. Em um nível intermediário (FE=80), os objetos classificados como vegetação foram reclassificados como vegetação arbórea e vegetação rasteira. Os objetos classificados como não vegetação foram reclassificados como solo e água. Para o nível com FE=50 (mesmo utilizado na classificação por árvore de decisão), os objetos classificados como solo foram reclassificados como solo exposto e voçoroca e a classe sombra foi introduzida. Neste nível, os objetos de vegetação rasteira e de vegetação arbórea foram reclassificados, para permitir o refinamento destas classes nesse nível com maior detalhamento, que permitiu identificar árvores isoladas.

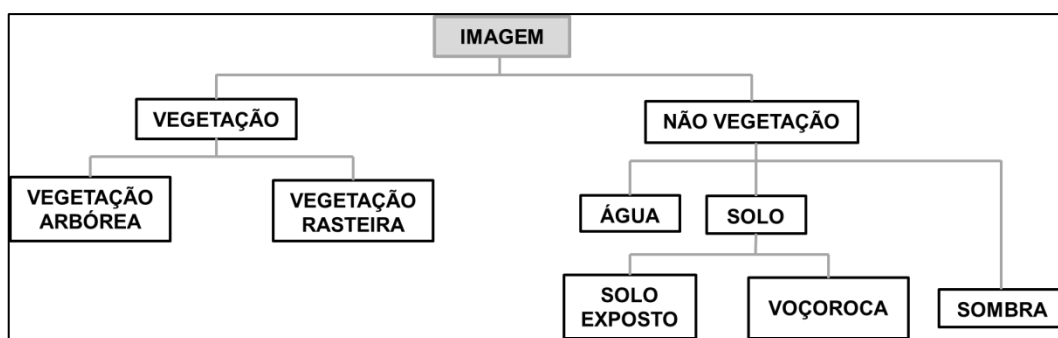


FIGURA 54 – REDE HIERÁRQUICA – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

#### - ÁREA DE ESTUDO A2:

A figura 55 ilustra a rede hierárquica para a área de estudo A2. Em um nível mais grosseiro (FE=80), os objetos foram separados em voçoroca e não voçoroca. No nível com FE=50, os objetos classificados como não voçoroca foram reclassificados como sombra e não sombra. Para o nível com FE=40 os objetos classificados como não sombra foram reclassificados como solo exposto e vegetação. A rede hierárquica foi estabelecida conforme a sugestão da árvore de

decisão, pois, após a realização de vários testes com outras organizações hierárquicas, esta foi a que apresentou os melhores resultados.

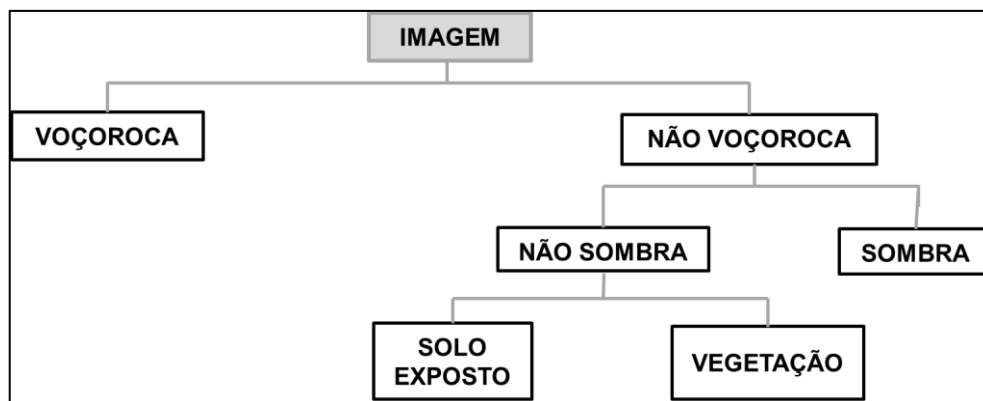


FIGURA 55 – REDE HIERÁRQUICA – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

### 5.7.2 Seleção de atributos e regras de pertinência fuzzy

Após a definição das redes hierárquicas, foram selecionadas amostras para cada classe, para as duas áreas de estudo. Buscou-se selecionar algumas amostras similares e outras diferentes das que foram usadas no treinamento da árvore de decisão, para evitar uma superadaptação da solução a um conjunto de amostras.

Os sistemas de voçoroca apresentam maiores similaridades quando correspondem a um mesmo estágio de evolução e tipo de solo, por exemplo. Na área A1, o sistema encontrava-se, na data de aquisição da imagem, em um estágio de evolução em que houve alargamento da cabeceira e aprofundamento do canal, processo também relacionado ao tipo de solo. Na área A2, percebe-se a ocorrência do recuo da cabeceira, a partir da união de vários dígitos, o que pode ser percebido pela textura dos dados nesta região da cena. Como o sistema está muito próximo a um corpo d'água, o alargamento da cabeceira se deu de forma mais rápida que o seu recuo, pois, em épocas de alta pluviosidade, aumenta a vazão do rio, que transborda e faz o carreamento de sedimentos. Como todos esses aspectos têm que ser considerados, não há como selecionar atributos que sejam apropriados à classificação de todos os sistemas de voçoroca. Para cada sistema há a

necessidade da investigação dos atributos discriminantes para esta classe, inclusive em função dos dados disponíveis. Em função disso, diferentes conjuntos de atributos e regras de pertinência fuzzy foram selecionados para as duas áreas de estudo e são explanados a seguir.

- ÁREA DE ESTUDO A1:

A figura 56 ilustra a rede hierárquica estabelecida, bem como os atributos e regras de pertinência utilizados para a classificação hierárquica da área de estudo A1.

No nível com FE=150 os objetos foram classificados em vegetação e não vegetação. Para tal, usou-se a regra fuzzy correspondente ao “intervalo total” de valores do NDVI entre 0,025 e 1 como atributo discriminante da classe vegetação. Para a classe não vegetação, usou-se a propriedade de similaridade entre classes, destacando-se que os objetos não classificados como vegetação deveriam ser classificados para a classe não vegetação.

No nível com FE=80, os objetos de vegetação foram reclassificados em vegetação arbórea, usando-se a regra fuzzy correspondente ao “intervalo total” de valores do MDSN entre 0,6 e 20 (metros, neste caso relativo à altura dos objetos no MDSN). Além da regra fuzzy, usou-se o classificador do vizinho mais próximo (*nearest neighbor* – NN) aplicado aos valores médios de NDVI e MDSN. Os objetos relativos à vegetação rasteira foram obtidos usando-se a regra fuzzy correspondente ao “intervalo total” de valores do MDSN entre -0,3 e 0,6, além do classificador do vizinho mais próximo aplicado aos valores médios de NDVI e MDSN.

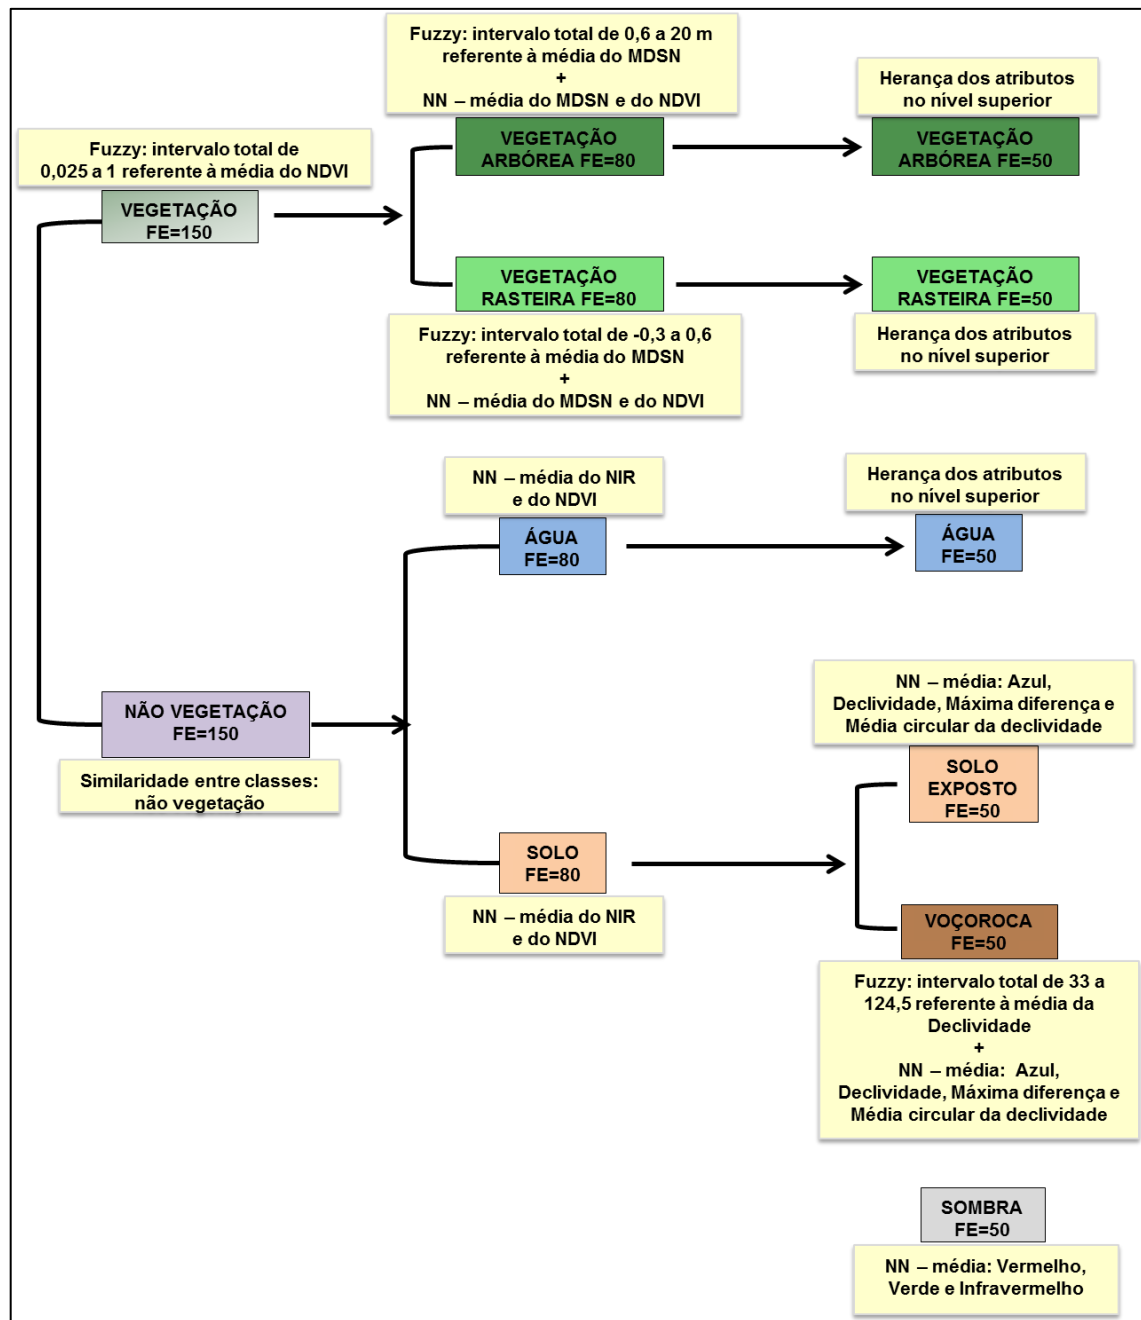


FIGURA 56 – REDE HIERÁRQUICA E ATRIBUTOS – ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)

Ainda no nível com FE=80, os objetos de não vegetação foram reclassificados em água e solo, usando-se o classificador do vizinho mais próximo aplicado aos valores médios de NDVI e da banda do infravermelho próximo (*near infrared* – NIR).

No nível com FE=50, os objetos de solo foram reclassificados em voçoroca e solo exposto. A classe voçoroca foi obtida usando-se a regra fuzzy correspondente

ao “intervalo total” de valores de Declividade entre 33 e 124,5 e o classificador do vizinho mais próximo aplicado aos valores médios das bandas: Azul, Declividade, Máxima Diferença e Média Circular da Declividade. Os objetos relativos a solo exposto foram obtidos usando-se o classificador do vizinho mais próximo aplicado aos valores médios das bandas: Azul, Declividade, Máxima Diferença e Média Circular da Declividade.

As regras de pertinência fuzzy utilizadas foram obtidas pela edição das regras geradas automaticamente com auxílio do programa eCognition. A partir da seleção de amostras e da escolha de um atributo, é possível gerar a regra fuzzy que melhor define o intervalo dos dados contido nas amostras. Como as variáveis para as quais foram usadas as regras fuzzy correspondiam ao NDVI (vegetação para valores entre 0 e 1) e ao MDSN (vegetação considerada como arbórea, neste estudo, com altura maior que 60cm), optou-se por usar a regra fuzzy que correspondia ao intervalo total dos dados compreendidos entre os limites estabelecidos.

A seleção dos atributos e das regras fuzzy foi realizada de forma empírica, a partir da solução apontada pela árvore de decisão. As regras fuzzy foram computadas para os outros atributos, mas, entretanto, ocorreram superposições entre os intervalos discriminantes de classes diferentes e, por isso, não foram utilizadas.

A rede hierárquica para a classificação pode ser explicitada na forma de uma base de regras:

→ No nível com FE = 150

Pela regra de pertinência fuzzy: **SE**  $0,025 < \text{NDVI} < 1$ , **ENTÃO** o objeto é da classe **VEGETAÇÃO**

**SE NÃO, ENTÃO** o objeto é da classe **NÃO VEGETAÇÃO**.

→ No nível com FE = 80

**SE É DA CLASSE VEGETAÇÃO:**

a) Pela regra de pertinência fuzzy: **SE**  $0,6 < \text{MDSN} < 20$ ;

Pelo classificador do vizinho mais próximo: **SE** o valor do MDSN está compreendido no intervalo de desvio-padrão da média das amostras de treinamento da imagem de MDSN, e

Pelo classificador do vizinho mais próximo: **SE** o valor do NDVI está compreendido no intervalo de desvio-padrão da média das amostras da imagem de NDVI,

**ENTÃO** o objeto é da classe **VEGETAÇÃO ARBÓREA**.

b) Pela regra de pertinência fuzzy: **SE**  $-0,3 < \text{MDSN} < 0,6$ ;

Pelo classificador do vizinho mais próximo: **SE** o valor do MDSN está compreendido no intervalo de desvio-padrão da média das amostras da imagem de MDSN, e

Pelo classificador do vizinho mais próximo: **SE** o valor do NDVI está compreendido no intervalo de desvio-padrão da média das amostras da imagem de NDVI,

**ENTÃO** o objeto é da classe **VEGETAÇÃO RASTEIRA**.

**SE NÃO É DA CLASSE VEGETAÇÃO:**

a) Pelo classificador do vizinho mais próximo: **SE** o valor do NDVI está compreendido no intervalo de desvio-padrão da média das amostras da imagem de NDVI, e

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Infravermelho (NIR) está compreendido no intervalo de desvio-padrão da média das amostras da imagem de NIR,

**ENTÃO** o objeto é da classe **ÁGUA**.

b) Pelo classificador do vizinho mais próximo: **SE** o valor do NDVI está compreendido no intervalo de desvio-padrão da média das amostras da imagem de NDVI, e

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Infravermelho (NIR) está compreendido no intervalo de desvio-padrão da média das amostras da banda da imagem de NIR,



**ENTÃO** o objeto é da classe **SOLO**.

→ No nível com FE = 50

SE É DA CLASSE VEGETAÇÃO ARBÓREA:

**SE** o objeto no nível classificado anterior é da classe vegetação arbórea

**ENTÃO** o objeto é da classe **VEGETAÇÃO ARBÓREA**.

SE É DA CLASSE VEGETAÇÃO RASTEIRA:

**SE** o objeto no nível classificado anterior é da classe vegetação rasteira

**ENTÃO** o objeto é da classe **VEGETAÇÃO RASTEIRA**.

SE É DA CLASSE ÁGUA:

**SE** o objeto no nível classificado anterior é da classe água **ENTÃO** o objeto é da classe **ÁGUA**.

SE É DA CLASSE SOLO:

a) **SE** o objeto no nível classificado anterior é da classe solo;

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Azul está compreendido no intervalo de desvio-padrão da média das amostras da imagem da banda do Azul;

Pelo classificador do vizinho mais próximo: **SE** o valor da Declividade está compreendido no intervalo de desvio-padrão da média das amostras da imagem de Declividade;

Pelo classificador do vizinho mais próximo: **SE** o valor do atributo Máxima Diferença está compreendido no intervalo de desvio-padrão da média das amostras para Máxima Diferença;

Pelo classificador do vizinho mais próximo: **SE** o valor do atributo Média Circular para a imagem de Declividade está compreendido no intervalo de desvio-padrão da média das amostras da Média Circular;

**ENTÃO** o objeto é da classe **SOLO EXPOSTO**.

b) Pela regra de pertinência fuzzy: **SE**  $33 < \text{Declividade} < 124,5$ ;

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Azul está compreendido no intervalo de desvio-padrão da média das amostras da imagem da

banda do Azul;

Pelo classificador do vizinho mais próximo: **SE** o valor da Declividade está compreendido no intervalo de desvio-padrão da média das amostras da imagem de Declividade;

Pelo classificador do vizinho mais próximo: **SE** o valor do atributo Máxima Diferença está compreendido no intervalo de desvio-padrão da média das amostras para Máxima Diferença;

Pelo classificador do vizinho mais próximo: **SE** o valor do atributo Média Circular para a imagem de Declividade está compreendido no intervalo de desvio-padrão da média das amostras da Média Circular;

**ENTÃO** o objeto é da classe **VOÇOROCA**.

**SE É NÃO VEGETAÇÃO, MAS NÃO É ÁGUA E NÃO É SOLO:**

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Vermelho está compreendido no intervalo de desvio-padrão da média das amostras da imagem da banda do Vermelho;

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Verde está compreendido no intervalo de desvio-padrão da média das amostras da imagem da banda do Verde;

Pelo classificador do vizinho mais próximo: **SE** o valor da banda do Infravermelho está compreendido no intervalo de desvio-padrão da média das amostras da imagem da banda do Infravermelho;

**ENTÃO** o objeto é da classe **SOMBRA**.

- ÁREA DE ESTUDO A2:

A figura 57 ilustra a rede hierárquica estabelecida, atributos e regras de pertinência utilizados para a classificação hierárquica da área de estudo A2.

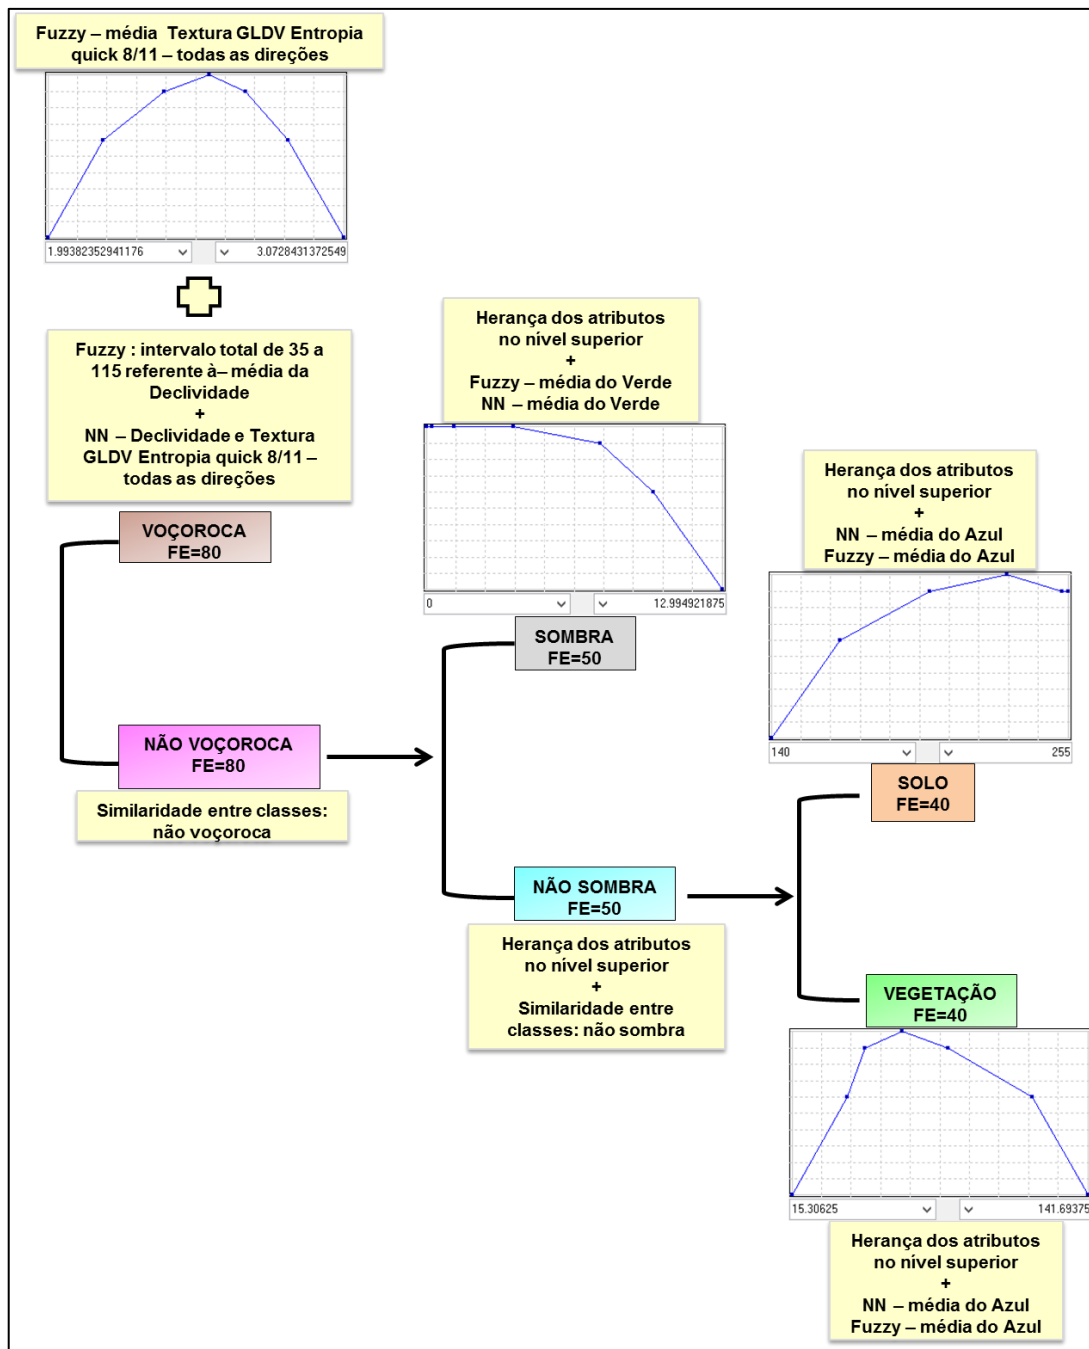


FIGURA 57 – REDE HIERÁRQUICA E ATRIBUTOS – ÁREA DE ESTUDO A2  
 FONTE: A AUTORA (2015)

No nível com FE=80 os objetos foram classificados em voçoroca e não voçoroca. A classificação dos objetos relativos à voçoroca foi feita em função de:

- regra fuzzy correspondente ao “intervalo total” de valores entre 35 e 115, da média da Declividade;
- regra fuzzy computada em função das amostras para a média da Textura de Haralick (GLDV Entropia quick 8/11 – todas as direções, para a imagem de

declividade), intervalo de valores entre 1,99 e 3,07, e

- classificador do vizinho mais próximo (NN) para média da Declividade e média da Textura de Haralick (GLDV Entropia quick 8/11 – todas as direções).

A classificação dos objetos não voçoroca se deu em função da regra invertida de similaridade entre classes, ou seja, da negação da classe voçoroca.

No nível com FE=50 os objetos não voçoroca foram reclassificados em sombra e não sombra. A classificação dos objetos relativos à sombra foi feita em função de:

- regra fuzzy computada em função das amostras para a média da banda Verde, com intervalo de valores entre 0 e 12,99;
- classificador do vizinho mais próximo (NN) para média da banda Verde, e
- herança dos atributos da classe não voçoroca (superobjetos no nível superior).

A classificação dos objetos não sombra se deu em função da regra invertida de similaridade entre classes, ou seja, da negação da classe sombra e da herança dos atributos da classe não voçoroca (superobjetos no nível superior).

No nível com FE=40 os objetos não sombra foram reclassificados em vegetação e solo. A classificação dos objetos relativos a solo foi feita em função de:

- edição da regra fuzzy computada em função das amostras para a média da banda Azul, com intervalo de valores entre 140 e 255;
- classificador do vizinho mais próximo (NN) para média da banda Azul, e
- herança dos atributos da classe não sombra (superobjetos no nível superior).

A classificação dos objetos vegetação se deu em função de:

- regra fuzzy computada em função das amostras para a média da banda Azul, com intervalo de valores (aproximados) entre 15 e 141;
- classificador do vizinho mais próximo (NN) para média da banda Azul, e
- herança dos atributos da classe não sombra (superobjetos no nível superior).

A rede hierárquica, explicitada na forma de uma base de regras:

→ No nível com FE = 80

Pela regra de pertinência fuzzy: **SE**  $35 < \text{Declividade} < 115$ ;

**SE** o atributo do objeto relativo à Textura de Haralick GLDV Entropia quick 8/11 – todas as direções estiver compreendido dentro da função de pertinência fuzzy gerada para o atributo, no intervalo entre 1,99 e 3,07;

Pelo classificador do vizinho mais próximo: **SE** o valor da Declividade está compreendido no intervalo de desvio-padrão da média das amostras de treinamento da imagem de Declividade;

Pelo classificador do vizinho mais próximo: **SE** o valor do atributo Textura de Haralick GLDV Entropia quick 8/11 – todas as direções está compreendido no intervalo de desvio-padrão da média das amostras de treinamento do atributo;

**ENTÃO** o objeto é da classe **VOÇOROCA**.

**SE NÃO, ENTÃO** o objeto é da classe **NÃO VOÇOROCA**.

→ No nível com FE = 50

**SE NÃO É DA CLASSE VOÇOROCA:**

**SE** o valor digital do objeto relativo à banda do Verde estiver compreendido dentro da função de pertinência fuzzy gerada para a banda do verde;

Pelo classificador do vizinho mais próximo: **SE** o valor digital do objeto na banda do Verde está compreendido no intervalo de desvio-padrão da média das amostras de treinamento da imagem da banda do Verde;

**ENTÃO** o objeto é da classe **SOMBRA**.

**SENÃO, o objeto é da classe NÃO SOMBRA**.

→ No nível com FE = 40

**SE É DA CLASSE NÃO SOMBRA:**

a) **SE** o valor digital do objeto relativo à banda do Azul estiver compreendido dentro da função de pertinência fuzzy gerada para as amostras para a banda do azul;

Pelo classificador do vizinho mais próximo: **SE** o valor digital do objeto na banda do Azul está compreendido no intervalo de desvio-padrão da média das amostras de treinamento da imagem da banda do Azul;

**ENTÃO** o objeto é da classe **SOLO**.

b) **SE** o valor digital do objeto relativo à banda do Azul estiver compreendido dentro da função de pertinência fuzzy gerada para as amostras para a banda do azul;

Pelo classificador do vizinho mais próximo: **SE** o valor digital do objeto na banda do Azul está compreendido no intervalo de desvio-padrão da média das amostras de treinamento da imagem da banda do Azul;

**ENTÃO** o objeto é da classe **VEGETAÇÃO**.

### 5.7.3 Classificação hierárquica

As figuras 58 e 59 ilustram as classificações obtidas pelo algoritmo de classificação hierárquica, para as duas áreas de estudo.

Para a avaliação da precisão da classificação, amostras de verificação foram selecionadas. Foram observadas a classe obtida pela classificação e, na imagem com composição colorida na região do visível, a classe a que o pixel pertencia (por fotointerpretação).

Para a área de estudo A1, as amostras de verificação foram escolhidas com base na malha de pontos ilustrada na figura 60. No nível com FE=50 existem 2394 objetos. Foram selecionadas 217 amostras, o que corresponde a uma margem de erro de 6,35% a um nível de confiança de 95%.

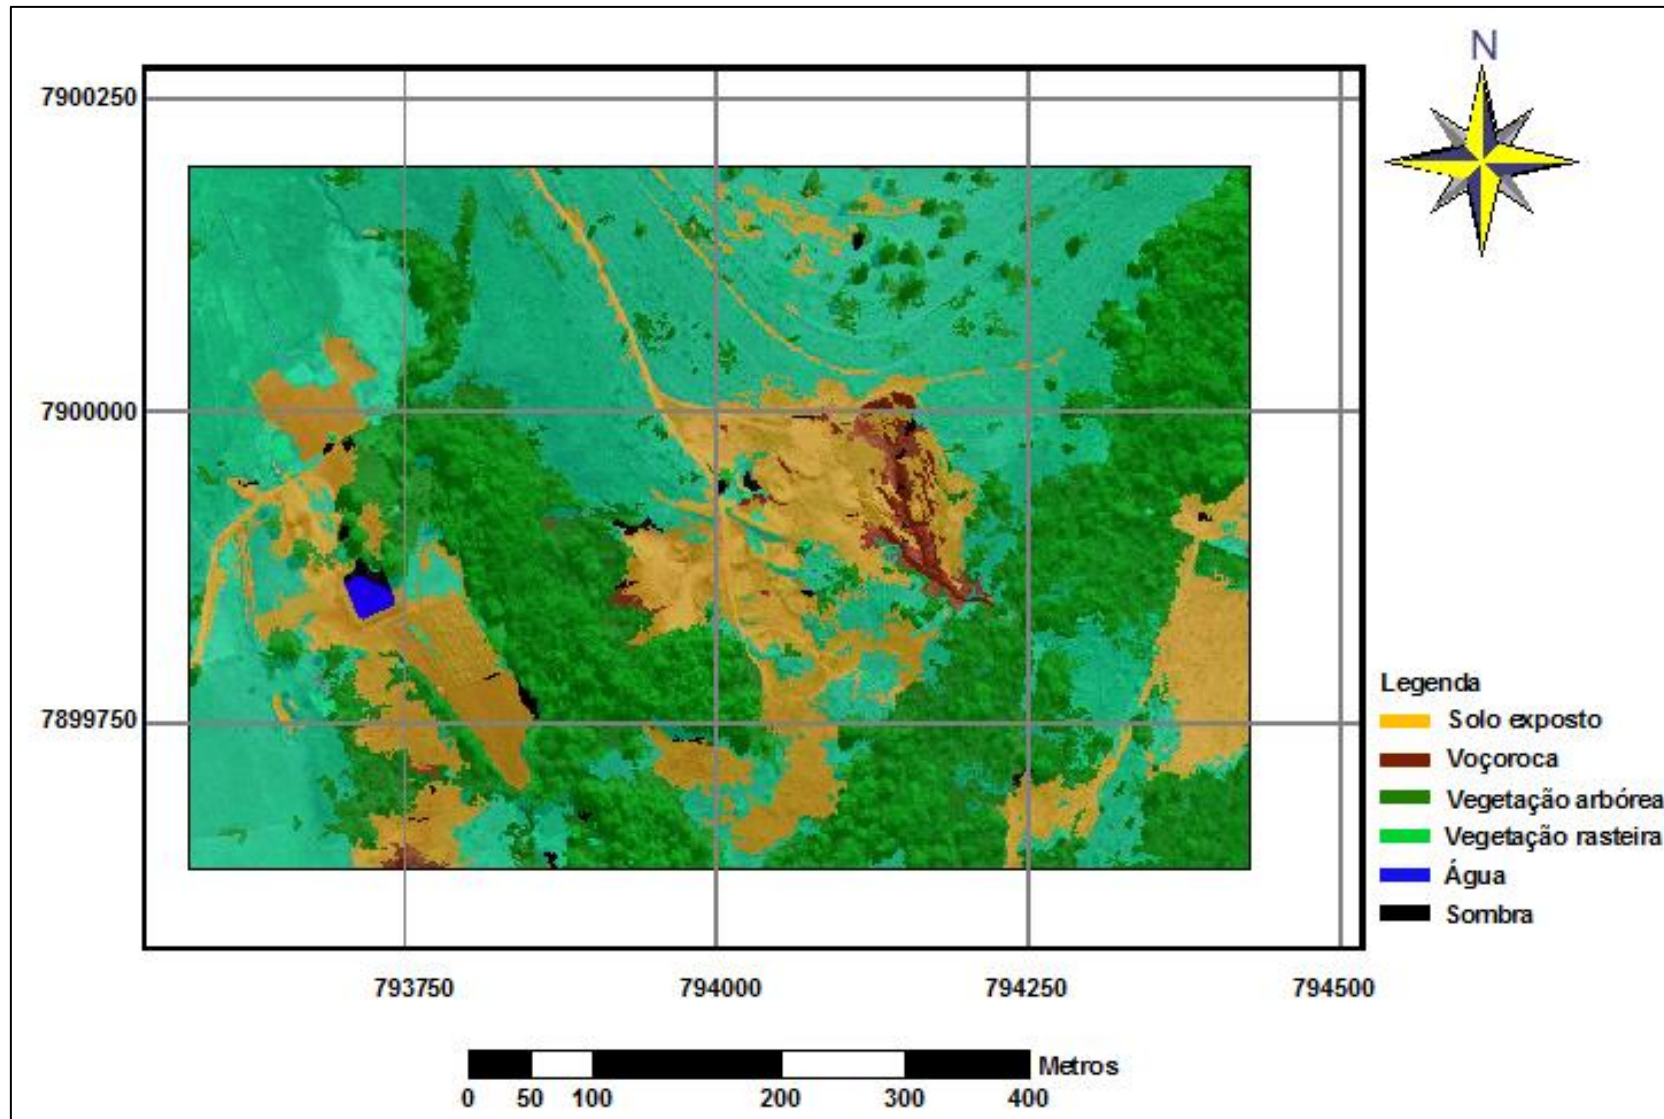


FIGURA 58 – CLASSIFICAÇÃO HIERÁRQUICA – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)



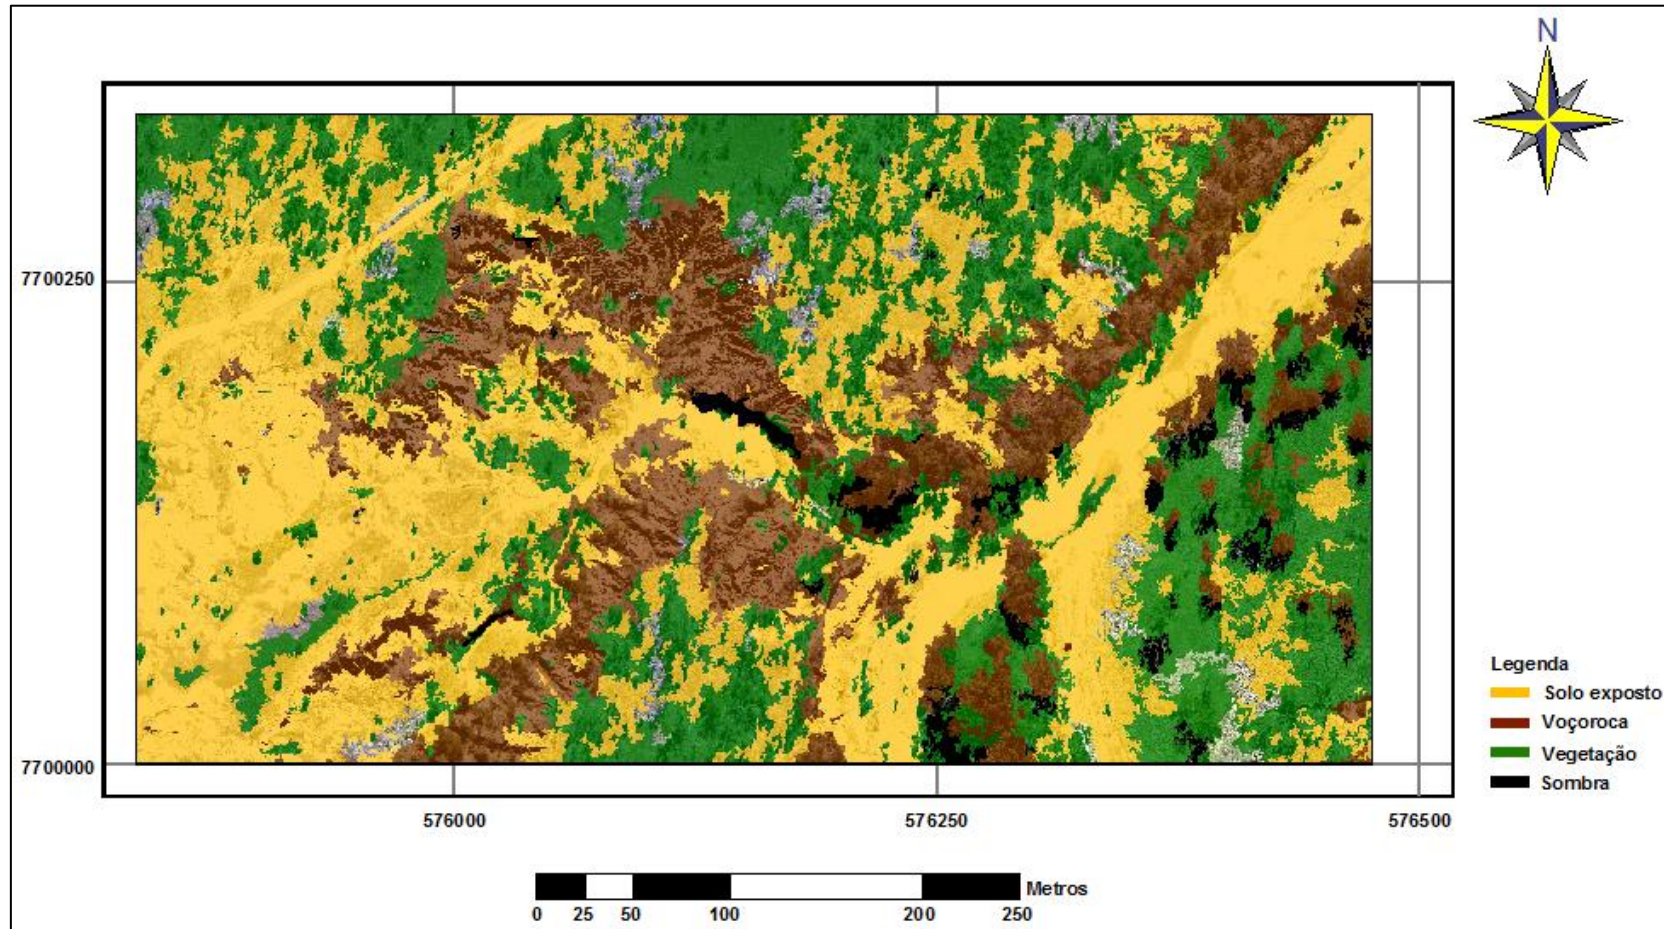


FIGURA 59 – CLASSIFICAÇÃO HIERÁRQUICA – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)




FIGURA 60 – DISTRIBUIÇÃO DAS AMOSTRAS DE VERIFICAÇÃO – ÁREA DE ESTUDO A1  
FONTE: A AUTORA (2015)

Conforme equações 21 e 22, o cálculo do número de amostras foi realizado por:

- para nível de significância de 95 %  $Z = 1,96$
- para erro de 6,35%

$$n_0 = \frac{Z^2 \cdot p \cdot (1-p)}{e^2} \Rightarrow 1,96^2 \cdot (0,5 \cdot 0,5) / 0,0635^2 = 238,18$$

$$n = \frac{n_0 \cdot N}{n_0 + (N-1)} \Rightarrow 238,18 \cdot 2394 / (238,18 + 2393) = 216,71$$

A tabela 3 representa a matriz de confusão obtida para as amostras de verificação. A acurácia global obtida foi de 82% e o índice kappa de 0,75 (kappa de 0,6 a 0,8 indica uma classificação muito boa).

Das amostras selecionadas como voçoroca uma foi classificada como vegetação rasteira e três como solo exposto. A maior confusão ocorreu entre as classes solo exposto e vegetação rasteira, pois é possível entrever o solo nas áreas com vegetação rasteira.



TABELA 3 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE VERIFICAÇÃO (CLASSIFICAÇÃO HIERÁRQUICA) – ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)

Classif. Classe Ref.	veg. rast.	veg. arb.	solo exposto	Voçor.	água	sombra	$\Sigma$	Acur. Prod.
veg. rasteira	57	5	5	-	-	-	67	85,07
veg. arbórea	5	59	-	-	-	-	64	92,19
solo exposto	13	2	42	3	-	1	61	68,85
voçoroca	1	-	3	14	-	-	18	77,78
água	-	-	-	-	3	-	3	100
sombra	1	1	-	-	-	2	4	50
$\Sigma$	77	67	50	17	3	3	217	
Acur. Usuário	74,03	88,06	84	82,35	100	66,67		

Para a área de estudo A2, as amostras de verificação foram escolhidas com base na malha de pontos ilustrada na figura 61. No nível com FE=50 existem 2265 objetos. Foram selecionadas 865 amostras, o que corresponde a uma margem de erro de 5% a um nível de confiança de 99%. A tabela 4 representa a matriz de confusão obtida para as amostras de verificação. A acurácia global obtida foi de 64,05% e o índice kappa de 0,46 (kappa de 0,4 a 0,6 indica uma classificação boa).




FIGURA 61 – DISTRIBUIÇÃO DAS AMOSTRAS DE VERIFICAÇÃO – ÁREA DE ESTUDO A2  
 FONTE: A AUTORA (2015)

Conforme equações 21 e 22, o cálculo do número de amostras foi realizado por (para nível de significância de 99 %;  $Z = 2,575$  e para erro de 5,0%):

$$n_0 = \frac{Z^2 * p * (1-p)}{e^2} \Rightarrow 2,575^2 * (0,5 * 0,5) / 0,05^2 = 663,06$$

$$n = \frac{n_0 * N}{n_0 + (N-1)} \Rightarrow 663,06 * 2265 / (663,06 + 2264) = 513,09$$

TABELA 4 – MATRIZ DE CONFUSÃO PARA AS AMOSTRAS DE VERIFICAÇÃO (CLASSIFICAÇÃO HIERÁRQUICA) – ÁREA DE ESTUDO A2  
FONTE: A AUTORA (2015)

Classif. Classe Ref.	vegetação	solo exposto	Voçor.	sombra	Σ	Acur. Prod.
vegetação	127	47	61	-	235	54,04
solo exposto	88	309	27	-	424	72,88
voçoroca	3	29	102	1	135	75,56
sombra	43	1	11	16	71	22,53
Σ	261	386	201	17	865	
Acur. Usuário	48,66	80,05	50,75	94,12		

Para melhor visualização dos resultados, a figura 62 apresenta as classificações por árvore de decisão e hierárquica, bem como uma ampliação de ambas para a região da voçoroca, comparada ao mapa de referência, gerado por fotointerpretação, para a área da voçoroca, relativa à área de estudo A1. A figura 63 apresenta o MDS e os resultados das classificações por árvore de decisão e hierárquica para a área de estudo A2.

Dentre os atributos mais relevantes para a delimitação da voçoroca, para o conjunto de dados e características da voçoroca da área de estudo A2, estão a declividade e a textura. A declividade reforça a hipótese de que dados altimétricos auxiliam na identificação desta classe, sendo imprescindíveis para análise de qualquer tipo e estágio do sistema voçoroca. Quanto à textura, é mais relevante no caso da existência de ravinamentos e dígito que estão se unindo em um processo de alargamento das feições. Há que se ressaltar que o uso de atributos de textura exige grande esforço computacional, tornando o processamento muito lento.

A seguir, são analisados os resultados para as duas áreas de estudo, separadamente.

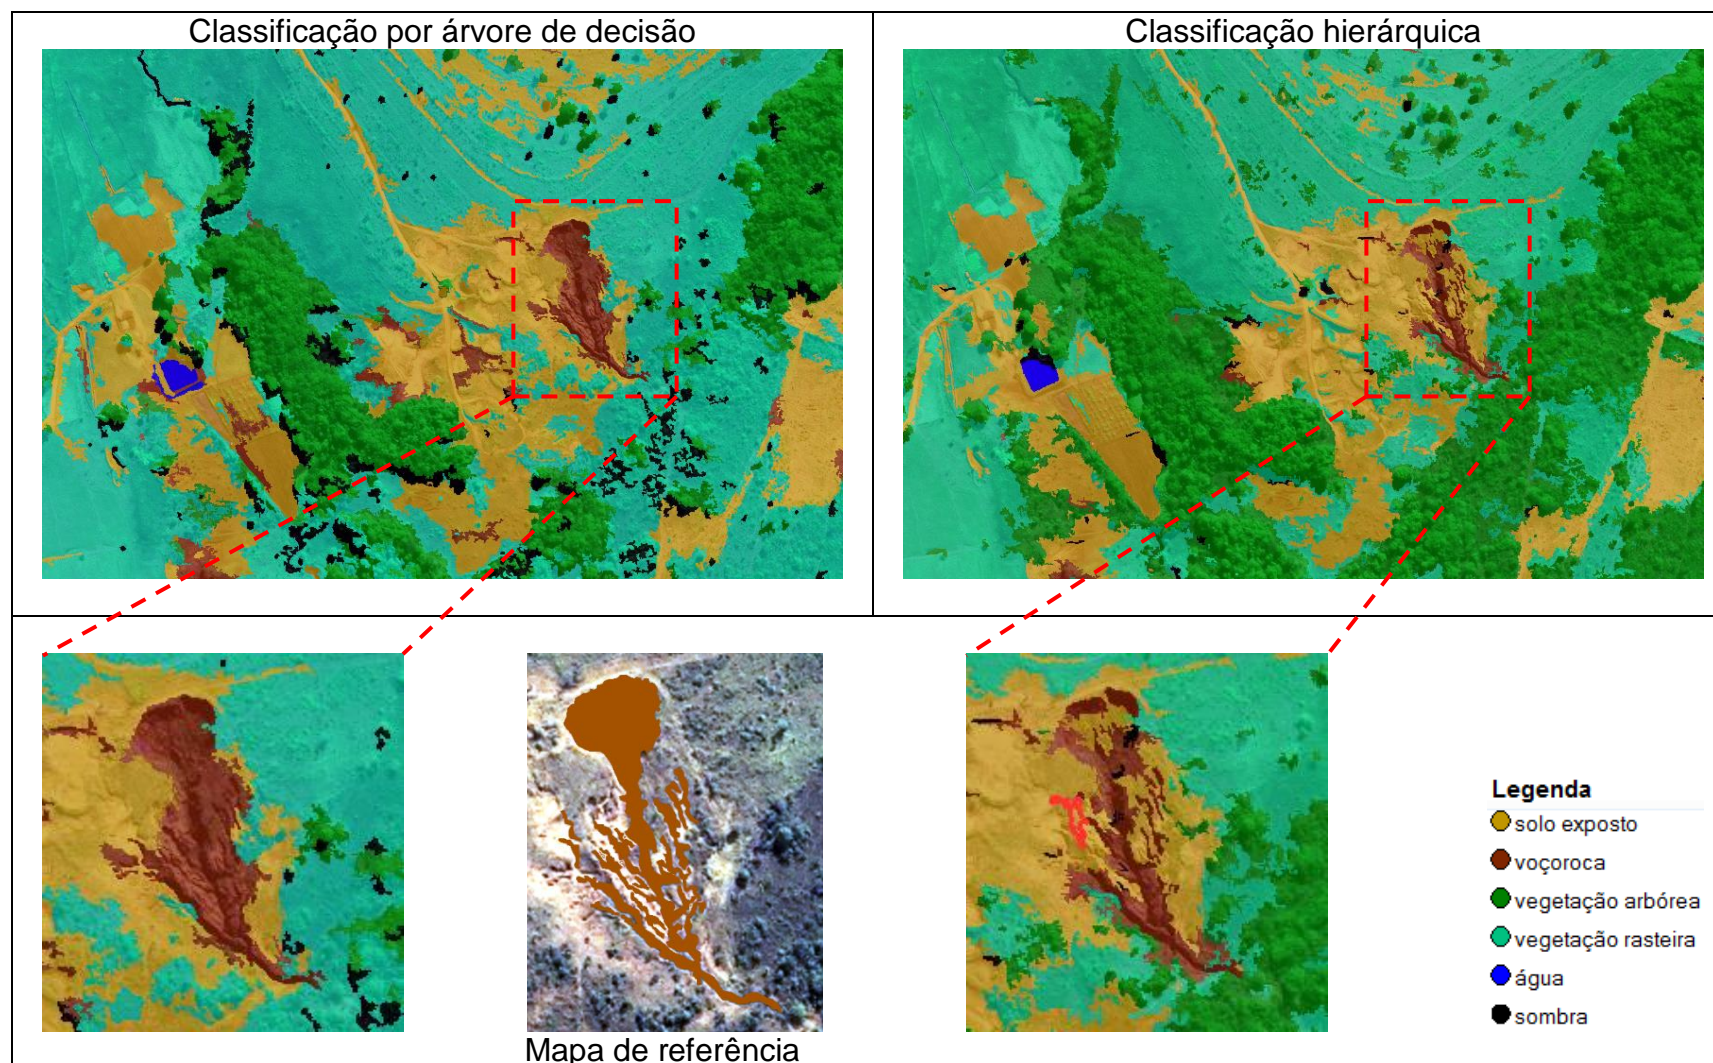


FIGURA 62 – CLASSIFICAÇÕES DA ÁREA DE ESTUDO A1  
 FONTE: A AUTORA (2015)



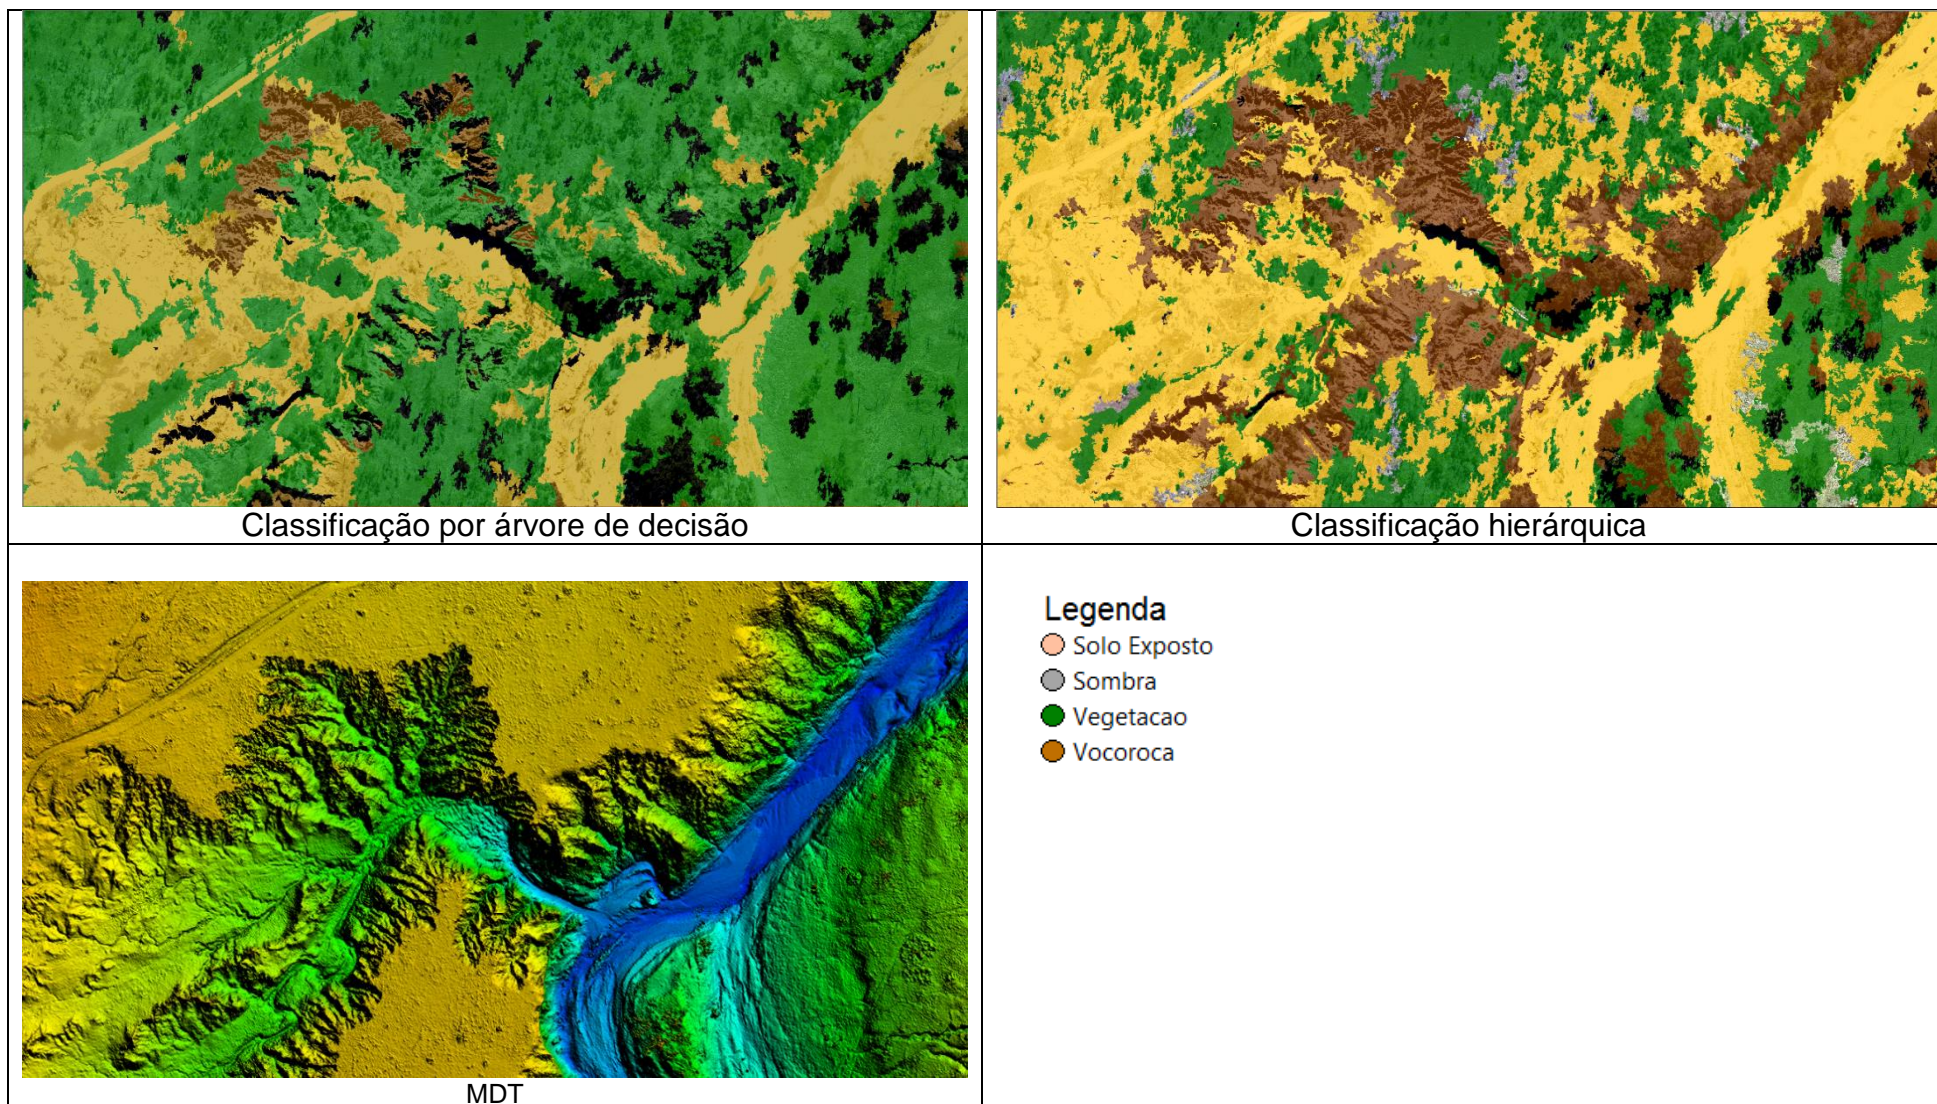


FIGURA 63 – CLASSIFICAÇÕES DA ÁREA DE ESTUDO A2  
 FONTE: A AUTORA (2015)

#### - ÁREA DE ESTUDO A1:

Na classificação por árvore de decisão, as áreas de sombra foram mais evidenciadas, entretanto, grandes áreas de vegetação arbórea foram erroneamente classificadas como vegetação rasteira. Isso pode ser explicado porque na base de regras de decisão não foi considerado o MDSN para separar estas duas classes e, inclusive, elas foram discriminadas em ramos diferentes da árvore. Algumas áreas de solo foram classificadas como voçoroca, mesmo a base de regras de decisão tendo usado a média circular da imagem de declividade como atributo discriminante. A área envolvente da voçoroca, relativa a solo exposto, foi erroneamente incorporada à classe voçoroca. Nesta separação de classes a árvore usou o atributo média circular da declividade. Este atributo considera o comportamento dos objetos vizinhos dentro de um anel, sendo os raios interno e externo desse anel definidos pelo usuário. Foram definidos raios interno e externo iguais, formando um círculo de raio igual a 3. Percebe-se, na figura 48 (imagem do atributo média circular da declividade) que, ao considerar dentro do círculo um objeto relativo a um dos dígitos da voçoroca, os vizinhos em um raio igual a 3 foram incorporados com o mesmo valor do objeto central. Dessa forma, os dígitos foram ligados ao canal principal da voçoroca, influenciando na classificação.

Na classificação hierárquica, obteve-se o delineamento de estradas, talhões e do corpo d'água existente na cena, bem como a identificação de árvores isoladas. Poucos elementos de solo exposto foram incorporados à classe voçoroca. Algumas regiões no entorno da vegetação arbórea, as quais apresentam declividade elevada, foram erroneamente classificadas como voçoroca. O interior da cabeceira da voçoroca foi classificado como solo exposto, já que o atributo discriminante usado nesta fase do processamento foi a declividade e, no interior da cabeceira, devido ao intenso transporte de sedimentos, esta região encontra-se planificada.

Realizando-se a análise visual, comparando-se com a imagem Ikonos, percebe-se que a classificação hierárquica permitiu o mapeamento do uso do solo e, especialmente, da discriminação da classe voçoroca. O resultado evidencia que a



árvore de decisão é útil na seleção de atributos e para um mapeamento preliminar, entretanto, a possibilidade de explicitação do conhecimento, o uso de regras de pertinência fuzzy e a classificação efetuada em diferentes níveis de segmentação, fazem da classificação hierárquica um método mais eficaz no mapeamento temático das coberturas do solo.

#### - ÁREA DE ESTUDO A2:

Na classificação por árvore de decisão, as áreas de sombra foram mais evidenciadas, não ocorreram objetos não classificados e não houve confusão entre as classes de voçoroca e vegetação (principalmente vegetação arbórea). Entretanto, poucos objetos foram classificados como voçoroca e regiões de solo exposto com tons de roxo foram classificados como vegetação (o que corresponderia a vegetação rasteira, neste caso, já que a rede semântica evidenciou apenas a classe vegetação, não separando em arbórea e rasteira).

Na classificação hierárquica, os objetos voçoroca foram bem identificados, mesmo os menores e mais isolados. Entretanto, muitas árvores foram incorporadas à classe voçoroca. Isso se deve ao fato de terem sido usadas a declividade e a textura como atributos determinantes desta classe. As árvores apresentam valores, para estes atributos, muito similares aos objetos de voçoroca, de forma que o índice de vegetação proposto, o IVBI, não foi suficiente para a separação destas classes. Avaliando-se apenas a classe de interesse, pode-se verificar que os atributos e regras de pertinência fuzzy selecionados foram efetivos na classificação da voçoroca.

A heterogeneidade da cena, a existência de muitos objetos pequenos isolados (árvores) e a existência de árvores sem folhagem (identificadas apenas em função do MDSN), dificultaram a separação das demais classes. Devido à grande mistura entre classes e a presença de vários objetos pequenos isolados (árvores), não foi gerado o mapa de referência por fotointerpretação para a área de estudo A2.

## 6 CONCLUSÕES

### 6.1 CONSIDERAÇÕES FINAIS

A produção de um mapa de uso do solo, com base em classificação de imagens, inicia-se com a definição da rede semântica, em função do conhecimento do analista, da fotointerpretação e de análises *in situ*. Em ambientes rurais, a rede semântica, comumente, engloba as classes de vegetação (arbórea, rasteira, área de cultivo, pasto, floresta, etc), corpos d'água (rios, tanques, açudes e lagos), solo exposto, áreas urbanizadas (estradas, construções, etc). Neste trabalho, propôs-se a inserção de uma subclasse, correspondente às feições erosivas do tipo voçoroca, em ambiente rural. Como as voçorocas, espectralmente, correspondem a uma mistura de solo, vegetação, água (quando do atingimento do lençol freático) e sombra, a discriminação da subclasse voçoroca necessita da investigação a respeito de dados auxiliares e atributos capazes de separar esta das demais classes com as quais ela se assemelha.

A hipótese estabelecida neste estudo, de que é possível delimitar as feições de voçoroca em um procedimento semiautomático de classificação, usando aerofotos ou imagens de satélite de alta resolução espacial, com a incorporação de dados altimétricos e de atributos não espectrais, como textura, usando-se abordagem orientada a objeto, árvores de decisão e classificação hierárquica, foi confirmada.

Como os sistemas de voçoroca são compostos por feições com formas e tamanhos bastante variáveis, as voçorocas podem ser delimitadas a partir de imagens de alta resolução espacial e mediante abordagem orientada a objeto, especialmente relacionada à classificação hierárquica. A resolução espacial de 1 m, do conjunto de dados para a área de estudo A1, mostrou-se suficiente para a identificação dos diferentes componentes do sistema voçoroca, como cabeceira, dígitos e canais.

A análise orientada a objeto implicou na necessidade de determinar parâmetros adequados para a segmentação dos objetos voçoroca. Para a classificação por árvores de decisão, verificou-se que os objetos oriundos da segmentação com  $FE=50$  foram representativos para a classe voçoroca. Para a classificação hierárquica da área A1 selecionou-se o  $FE=50$ , devido à presença de canais secundários e dígitos, de dimensões inferiores a 2 m. Para a área A2, como é um sistema de voçoroca com características distintas da voçoroca da área A1 (não apresenta a formação de canais e dígitos, havendo uma regressão erosiva uniforme, formando uma grande cabeceira) e não tendo feições de dimensões submétricas, selecionou-se o  $FE=80$ .

Como os sistemas de voçoroca apresentam maiores similaridades quando correspondem a um mesmo estágio de evolução e tipo de solo, por exemplo, não há como selecionar atributos que sejam apropriados à classificação de todos os sistemas, sendo necessária a investigação dos atributos discriminantes para cada sistema de voçoroca, inclusive em função dos dados disponíveis e classes de uso do solo existentes na cena.

A investigação de atributos é realizada com maior rapidez de processamento quando são consideradas técnicas de mineração de dados, como os algoritmos de indução de árvores de decisão. Entretanto, para agilizar o processamento e requerer menor potencial computacional, pode-se realizar uma análise prévia dos atributos disponíveis, de acordo com os recursos de programa que se está utilizando, usando como dados de entrada para a indução, apenas os mais relevantes.

A mineração de dados por algoritmos de indução de árvore de decisão mostrou-se uma metodologia robusta, de fácil utilização e rápido processamento. A análise dos atributos selecionados é de fácil compreensão, devido à apresentação da mineração dos dados no formato de uma árvore hierárquica binária. Isto permitiu a reprodução dos dados obtidos na classificação hierárquica. Além disso, a mineração de dados subsidia o processo de tomada de decisão, em substituição ao empirismo, fornecendo uma base de regras de decisão preliminar, que pode ser

ajustada de acordo com o conhecimento especialista para realização da classificação hierárquica, por exemplo. Uma desvantagem da classificação por árvores de decisão é que só é possível realizá-la em um nível de segmentação.

Para os conjuntos de dados disponíveis e para as especificidades das duas áreas de estudo, os atributos que se mostraram mais relevantes na discriminação da classe voçoroca foram a declividade e a textura. No que tange ao conjunto de dados, ressalta-se que o uso de dados espectrais, de alta resolução espacial, aliado ao uso de dados altimétricos possibilita a delimitação das voçorocas.

Realizando-se a análise visual das classificações resultantes da aplicação das árvores de decisão, percebe-se a necessidade de refinamento do procedimento automático, comprovando que este não apresenta a mesma qualidade dos procedimentos semiautomáticos. Entretanto, são úteis para seleção de atributos, estabelecimento de uma base de regras de decisão preliminar e para uma avaliação rápida do resultado possível, a partir do conjunto de dados disponível.

A classificação hierárquica permitiu a melhora da classificação pela inserção de conhecimento especialista, com a incorporação de outros atributos (por exemplo, para a área de estudo A1, o uso do MDSN para distinguir vegetação arbórea de rasteira, que não foi apontado pela árvore de decisão), além dos selecionados pelas árvores de decisão, e de regras de pertinência fuzzy.

De forma geral, como a voçoroca não constitui uma classe de uso do solo (sendo resultante da mistura de classes como solo, vegetação, sombra e água) a delimitação da mesma não pode ser obtida por procedimentos de classificação orientados a pixel. Como ela constitui um objeto, somente em procedimentos de classificação orientados a objeto é que a mesma pode ser delimitada. Devido à mistura espectral com as classes supracitadas, a incorporação de dados não espectrais faz-se mister para a classificação, como é o caso de dados altimétricos e atributos de textura. A classificação automática, por árvore de decisão, permitiu a delimitação da voçoroca. Entretanto, como esse tipo de procedimento não faz uso de lógica fuzzy, as misturas entre as classes não pode ser evidenciada na base de

regras de decisão. Além disso, a classificação é realizada apenas para um fator de escala, não permitindo identificar todas as feições constituintes do sistema voçoroca (como canais e dígitos). Na classificação hierárquica, o procedimento é realizado em escalas diferentes, permitindo o uso da lógica fuzzy para descrever diferentes graus de pertinência a cada classe, o que torna o método bastante atraente para casos como o deste estudo, onde há mistura de classes. Assim, a classificação obtida com o método semiautomático, de classificação hierárquica, mostrou-se mais fidedigna à realidade de campo, por permitir o uso de escalas diferentes, inserção de incerteza (pela lógica fuzzy) e inserção de conhecimento (pela base de regras estabelecida), quando comparada à classificação automática por árvore de decisão.

Destaca-se ainda, que o índice proposto ICBI (Índice de Contraste Baseado em Intensidade), permitiu o realce do solo, mostrando-se uma alternativa nos casos da indisponibilidade da banda do infravermelho, mas da disponibilidade da banda de intensidade do ALS.

## 6.2 RECOMENDAÇÕES

Apesar dos resultados satisfatórios obtidos, a quase total inexistência de dados de alta resolução espacial e altimétricos para áreas rurais é um empecilho para a aplicação da metodologia. Como são dados dispendiosos, em termos financeiros, dificilmente ocorre a aquisição destes dados para áreas rurais, onde não é realizado planejamento urbano, que necessita de maior nível de detalhamento. Para monitoramento ambiental, em ambientes rurais, comumente são usadas imagens de média resolução espacial e raramente são coletados dados altimétricos por ALS. Apesar de se poderem obter mapas de curvas de nível e de declividade a partir de cartas topográficas, geralmente estes apresentam baixa resolução espacial, o que pode não permitir delimitar voçorocas, se estas não ocuparem grandes áreas. Recomenda-se, portanto, que a metodologia seja aplicada para voçorocas em ambientes urbanos, que apresentarão uma rede semântica distinta da de ambientes

rurais, ambientes para os quais há maior disponibilidade de dados.

Como se observou nas duas áreas de estudo, os sistemas de voçoroca não são similares. Recomenda-se, portanto, a aplicação da metodologia a outros sistemas, com características e dimensões diferentes.

Como as áreas internas das voçorocas não foram incorporadas à classe voçoroca usando-se os métodos de classificação por árvores de decisão e hierárquica, recomenda-se inserir regras de contexto, com a finalidade de incorporar estas áreas e diminuir a confusão com a classe de solo exposto.

## REFERÊNCIAS

- ACKERMANN, F. Airborne laser scanning – present status and future expectations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, p. 64-67, 1999.
- ALKHASAWNEH, M.; NGAH, U. K.; TAY, L. T.; ISA, N. A. M.; AL-BATAH, M. S. Modeling and Testing Landslide Hazard Using Decision Tree. **Journal of Applied Mathematics**, v. 2014, p. 1-9, 2014.
- ALVES, R. R. **Monitoramento dos processos erosivos e da dinâmica hidrológica e de sedimento de uma voçoroca: estudo de caso na Fazenda do Glória na zona rural de Uberlândia-MG**. 105 p. Dissertação (Mestrado em Geografia) – Instituto de Geografia, Universidade Federal de Uberlândia, Uberlândia, 2007.
- ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 147 p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.
- ARAKI, H. **Fusão de informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial**. 126 p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2005.
- AXELSSON, P. Processing of laser scanner data - algorithms and applications. **ISPRS Journal of Photogrammetry & Remote Sensing**, Netherlands, vol. 54, p. 138– 147, July 1999.
- AXELSSON, P. DEM generation from laserscanner data using adaptive TIN models. **International Archives of Photogrammetry and Remote Sensing**, XXXIII, Part B3, p. 85-92, 2000.
- BAATZ, M.; SCHÄPE, A. Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. In: 2<sup>nd</sup> International Symposium: Operationalization of Remote Sensing, ITC Netherlands, 1999.
- BAATZ, M.; BENZ, U.; DEHGHANI, S.; HEYNEN, M.; HÖLTJE, A.; HOFMANN, P.; LINGENFELDER, I.; MIMLER, M.; SOHLBACH, M.; WEBER, M.; WILLHAUCK, G. **eCognition Object Oriented Image Analysis – Guia do usuário**. Germany: Definiens Imaging, 2001.
- BACCARO, C. A. D. Processos Erosivos no Domínio do Cerrado. In: GUERRA, A. J. T. (Org.); SILVA, A. S. (Org.); BOTELHO, R. G. M. (Org.). **Erosão e Conservação dos Solos: Conceitos, Temas e Aplicações**. 6. ed. Rio de Janeiro: Bertran Brasil, 2010. p. 195-227.
- BALTSAVIAS, E. P. Airborne LASER Scanning: Basic Relations and Formulas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, p. 199-214, 1999.



BARBERA, G. G. Artigo - **Aumento na agricultura intensiva de regadio.**

Disponível em:

< [http://www.unibas.it/desertnet/dis4me/issues/issue\\_irrigation\\_pt.htm](http://www.unibas.it/desertnet/dis4me/issues/issue_irrigation_pt.htm) > Acesso em: 02/09/2012.

BENZ, U.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I. & HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, p.239-258, 2004.

BERRY, M. J. A.; LINOFF, G. S. **Data Mining Techniques** – For marketing, sales and customer relationship management. Second Edition. Indiana: Wiley Publishing Inc., 2004.

BETTS, H. D.; DeROSE, R. C. Digital elevation models as a tool for monitoring and measuring gully erosion. **International Journal of Applied Earth Observation and Geoinformation**, v. 1, p. 91-101, 1999.

BEZERRA, J. F. R.; GUERRA, A. J. T.; RODRIGUES, S. C. Utilização da fotocomparação na reabilitação de áreas degradadas por erosão, a partir de uma estação experimental, Uberlândia – MG. **Revista de Geografia da Universidade Federal de Pernambuco**, v. 28, nº 2, p. 149-164, 2011.

BIGARELLA, J. J. **Estrutura e origem das paisagens tropicais e subtropicais**. 2. ed. Florianópolis: Editora da UFSC, 2007. v. 3.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. **Environmental information for planning**, Metropolis-Verlag v. 2, p. 555-570, 2000.

BLASCHKE, T.; HAY, G. J. Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structures. In: International Archives of Photogrammetry and Remote Sensing, v. 34, Part 4/W5 “Challenges in Geospatial Analysis, Integration and Visualization”, 2001, Athens-Georgia, USA.

BLASCHKE, T.; STROBL, J. What’s wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GIS – Zeitschrift für Geoinformationssysteme**, v. 17, p. 12-17, 2001.

BREIMAN, L.; FRIEDMAN, J. H.; OLSEN, R. A.; STONE, C. J. **Classification and Regression Trees**. Belmont, CA: Wadsworth, 1984.

CASTRO, S. S. Impactos Ambientais em Bacias Hidrográficas. In: X Simpósio Ambientalista do Cerrado, 2004, Goiânia. Minicurso proferido.

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. Curitiba: UFPR Curso de Pós-graduação em Ciências Geodésicas, 2009.

CHRISTOFOLETTI, A. **Geomorfologia**. 2. ed. rev. e amp. São Paulo-SP: Edgard Blücher, 1980.

CHUVIECO, E.; HUETE, A. **Fundamentals of Satellite Remote Sensing**. USA: CRC Press, 2010.

COSTA, F. M.; BACELLAR, L. A. P. Analysis of the influence of gully erosion in the flow pattern of catchment streams, Southeastern Brazil. **Catena**, v. 69, p. 230-238, 2007.

CPRM - COMPANHIA DE PESQUISA DE RECURSOS MINERAIS. Serviço Geológico do Brasil. **Atlas Geoambiental - Projeto Paisagens Geoquímicas e Ambientais do Vale do Ribeira**. Disponível em: <[http://www.cprm.gov.br/gestao/ppga\\_valedoribeira/Registros%20fotogr%E1ficos/cajati.htm](http://www.cprm.gov.br/gestao/ppga_valedoribeira/Registros%20fotogr%E1ficos/cajati.htm)> Acesso em: 28/06/2015.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1993.

DABA, S.; RIEGER, W.; STRAUSS, P. Assessment of gully erosion in eastern Ethiopia using photogrammetric techniques. **Catena** 50, p. 273-291, 2003.

DAEE/IPT. **Controle de erosão: bases conceituais e técnicas; diretrizes para o planejamento urbano e regional; orientações para o controle de boçorocas urbanas**. Secretaria de Energia e Saneamento. Departamento de Águas e Energia Elétrica do Estado de São Paulo. Instituto de Pesquisas Tecnológicas do Estado de São Paulo. São Paulo, 1989. 92 p.

DAL POZ, A. P. Filtragem de dados de varredura a laser: Princípios e exemplos. In: **Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR**. Foz do Iguaçu, 2013. INPE. p. 6057-6064.

DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, v. 102, p. 1-11, 2006.

DYKINGA, J. **Severe soil erosion in a wheat field near Washington State University**. Agricultural Research Service – United States Department of Agriculture. Disponível em: <<http://www.ars.usda.gov/is/graphics/photos/k5951-1.htm>> Acesso em: 27/06/2015.

EUSTACE, A.; PRINGLE, M.; WITTE, C. Give me the dirt: Detection of Gully Extent and Volume Using High-Resolution LIDAR. In: JONES, S.; REINKE, K. **Innovations in Remote Sensing and Photogrammetry: Lecture Notes in Geoinformation and Cartography**. Berlin: Editora Springer, 2009.

FADULL, H. M.; SALIHL A. A.; ALI, I. A.; INANAGA, S. Use of remote sensing to map gully erosion along the Atbara River, Sudan. **JAG**, v. 1, p. 175-180, 1999.

FERREIRA, D. F. **Estatística Básica**. 2ª edição revisada. Lavras-MG: Editora UFLA, 2009.

FLUGEL, W.; MÄRKER, M.; MORETTI, S.; RODOLFI, G.; SIDROCHUK, A. Integrating geographical information systems, remote sensing, ground truthing and modelling approaches for regional erosion classification of semi-arid catchments in South Africa. **Hydrological Processes**, v. 17, p. 929-942, 2003.

FORMAN, R. **Land mosaics: The ecology of landscapes and regions**. Cambridge: Cambridge University Press, p. 632, 1995.

FRANCISCO, B. A.; NUNES, J. O. R. Aplicação de metodologia de estaqueamento para estudo do processo de voçorocamento no município de Rancharia-SP. **Caderno Prudentino de Geografia**, v. 1, nº 31, 2009.

GHOSE, M. K.; PRADHAN, R.; GHOSE, S. S. Decision tree classification of remotely sensed satellite data using spectral separability matrix. **International Journal of Advanced Computer Science and Applications**, v. 1, nº 5, p. 93-101, 2010.

GILAD, U.; DENHAM, R.; TINDALL, D. Gullies, google earth and the Great Barrier Reef: a remote sensing methodology for mapping gullies over extensive areas. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIX-B8, 2012, XXII ISPRS Congress, Melbourne, Australia. p. 469-473.

GONÇALVES, C. F. F. **Estatística**. Londrina: Editora da Universidade Estadual de Londrina – EDUEL, 2002.

GONZALEZ, R.; WOODS, R. **Processamento de imagens digitais**. Tradução CESAR JUNIOR, R. M.; COSTA, L. da F. São Paulo-SP: Edgard Blucher, 2008.

GUERRA, A. J. T. Processos erosivos nas encostas. In: GUERRA, A. J. T. (Org.); CUNHA, S. B. (Org.). **Geomorfologia: uma atualização de bases e conceitos**. Rio de Janeiro: Bertran Brasil, 1994. p. 149-209.

\_\_\_\_\_. Experimentos e monitoramentos em erosão dos solos. XI Simpósio Brasileiro de Geografia Física Aplicada. In: **Revista do Departamento de Geografia – USP**, nº 16, p. 32-37, 2005a.

\_\_\_\_\_. O início do processo erosivo. In: GUERRA, A. J. T. (Org.); SILVA, A. S. (Org.); BOTELHO, R. G. M. (Org.). **Erosão e Conservação dos Solos: Conceitos, Temas e Aplicações**. 2. ed. Cap. 1. Rio de Janeiro: Bertran Brasil, 2005b. p. 17-55.

GUERRA, A. J. T.; BOTELHO, R. G. M. Erosão dos Solos. In: CUNHA, S. B. (Org.); GUERRA, A. J. T. (Org.). **Geomorfologia do Brasil**. 2. ed. Rio de Janeiro: Bertran Brasil, 2001. p. 181-227.

GUERRA, A. T.; GUERRA, A. J. T. **Novo dicionário geológico-geomorfológico**. Rio de Janeiro: Bertran Brasil, 1997.

HAN, J.; KAMBER, M.; PEI, J. **Data Mining – concepts and techniques**. Third Edition. USA: Elsevier Inc., 2012.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. Textural Features for Image Classification. **IEEE Transactions on systems, man, and cybernetics**, v. SMC-3, nº. 6, p. 610-621, 1973.

HARALICK, R. M.; SHAPIRO, L. G. Image Segmentation Techniques. **Computer vision, Graphics and Image Processing**, v. 29, p. 100-132, 1985.

HARRISONBURG HIGH SCHOOL. Sítio da escola. Disponível em:  
< <http://staff.harrisonburg.k12.va.us/~cwalton/solpracticetestgeography.htm> > Acesso em: 28/06/2015.

HESSEL, R., VAN ASCH, T. Modelling gully erosion for a small catchment on the Chinese Loess Plateau. **Catena**, v. 54, p.131-146, 2003.

HOFMANN, P. HEINHARDT, W. The extraction of GIS features from high resolution imagery using advanced methods based on additional contextual information – first experiences. In: **International Archives of Photogrammetry and Remote Sensing**, v. XXXIII, Supplement B4, Amsterdam, 2000.

IPT - INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO. **Orientações para o combate à erosão no Estado de São Paulo, Bacia do Peixe, Paranapanema**. São Paulo, 6v. (IPT, Relatório 24:739), 1986.

IPT - INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO. **Voçoroca em Bauru – SP**. Disponível em:  
< <http://www.geologiadobrasil.com.br/vossoroca.html> > Acesso em: 28/06/2015.

JAMES, L. A.; WATSON, D. G.; HANSEN, W. Using LiDAR data to map gullies and headwater streams under forest canopy: South Carolina, USA. **Catena**, v. 71, p. 132-144, 2007.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução da segunda edição. São José dos Campos-SP: Parêntese Editora, 2009.

JOHANSEN, K.; TAIHEI, S.; TINDALL, D.; PHINN, S. Object-based Monitoring of Gully Extent and Volume in North Australia using LiDAR Data. **Proceedings of the 4th GEOBIA**. Rio de Janeiro, p. 168-173, 2012.

KING, C.; BAGHDADI, N.; LECOMTE, V.; CERDAN, O. The application of remote-sensing data to monitoring and modelling of soil erosion. **Catena**, v. 62, p. 79-93, 2005.

KNIGHT, J.; SPENCER, J.; BROOKS, A.; PHINN, S. Large-area, high-resolution remote sensing based mapping of alluvial gully erosion in Australia's tropical rivers. In: **Proceedings of the 5th Australian Stream Management Conference: Australian Rivers: Making a Difference**. Charles Sturt University, Thurgoona, New South Wales, 2007. p. 199–204.

LABOGEF-UFG. Artigo: **Geomorfologia Aplicada: Erosões hídricas – voçorocas**. Laboratório de Geografia Física da Universidade Federal de Goiás. Disponível em: <<http://www.labogef.iesa.ufg.br/labogef/ensino/>> Acesso em: 01/09/2012.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, p.159-174, 1977.

LEAL, P. C. B.; RODRIGUES, S. C. Uso e comparação do método de estaqueamento, o método DGPS e geoprocessamento no monitoramento de uma área erosiva na Fazenda do Glória – Uberlândia-MG. **GEOUSP – Espaço e Tempo**, São Paulo, nº 29, p. 18-35, 2011.

LEONARDI, F. **Abordagens cognitivas e mineração de dados aplicadas a dados ópticos orbitais e de laser para a classificação de cobertura do solo urbano**. 134 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.

LEONARDI, F.; ALMEIDA, C.; FONSECA, L.; TOMÁS, L.; ALBUQUERQUE, P. G.; OLIVEIRA, C. Elevation Accuracy Assessment of a DSM and DTM Generated for an Urban Area from the ALTM 2025 Airborne Laser Scanning Sensor. In: **Second International Workshop on Earth Observation and Remote Sensing Applications**. 2012.

LE ROUX, J. J. Monitoring soil erosion in South Africa at a regional scale. In: **Report for the council of geoscience geohazards project**, 2011. Disponível em: <[http://www.geohazard.org.za/images/docs/subsection\\_downloads/erosion.pdf](http://www.geohazard.org.za/images/docs/subsection_downloads/erosion.pdf)> Acesso em: 28/06/2015.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote Sensing and Image Interpretation**. 6ª Edition. USA: John Wiley & Sons, 2008.

LUZ, N. B. **Integração de Análise Orientada a Objetos e Árvores de Decisão para Classificação de Sub-tipologias de Floresta Ombrófila Mista**. 156 p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2011.

MAIMOM, O.; ROKACH, L. **Data mining and knowledge discovery handbook**. Second Edition. USA: Springer, 2010.

MARTINEZ-CASASNOVAS, J. A.; ZARAGOZA, T. C. Gully Erosion Mapping by Remote Sensing Techniques. A case study in the Anoia – Penedès region (NE Spain). In: **Libro de resúmenes del “Primer Congreso Europeo sobre el Control de la Erosión”**. Session 6: measuring and modelling erosion processes. Sitges (Barcelona), 1996.

MARTÍNEZ-CASANOVAS, J. A. A spatial information technology approach for the mapping and quantification of gully erosion. **Catena**, v. 50, p. 293-308, 2003.

MARTÍNEZ-CASANOVAS, J. A.; RAMOS, M. C.; POESEN, J. Assessment of sidewall erosion in large gullies using multi-temporal DEMs and logistic regression analysis. **Geomorphology**, v. 58, p. 305-321, 2004.

MARZOLFF, I., POESEN, J. The potential of 3D gully monitoring with GIS using high-resolution aerial photography and a digital photogrammetry system. **Geomorphology**, v. 111 ISSS 1-2, p. 48-60, 2009.

MITCHELL, T. **Machine Learning**. USA: McGraw-Hill, 1997.

MORGAN, R. P. C. **Soil Erosion and Conservation**. Oxford: Blackwell Publishing, 2005.

NASCIMENTO, L. **Apuarema Agora**. 2013. Disponível em: <<http://apuaremaagora.blogspot.com.br/2013/07/poca-de-agua-na-estrada-que-liga.html>> Acesso em: 28/06/2015.

NWC – **National Water Comission** - Australian Government. Sítio da NWC. Disponível em: < <http://archive.nwc.gov.au/library/topic/planning/report-card/queensland/planning-areas/water-resource-burdekin-basin-plan> > Acesso em: 28/06/2015.

OLDEMAN, L. R.; HAKKELING, R. T. A.; SOMBROEK, W. G. **World map of the status of human-induced soil degradation - an explanatory note**. GLASOD Explanatory Notes, 1991. Disponível em: < [http://www.isric.org/sites/default/files/ExplanNote\\_1.pdf](http://www.isric.org/sites/default/files/ExplanNote_1.pdf) > Acesso em 28/06/2015.

OLDEMAN, L. R.; VAN LYNDEN, G. W. J. **Revisiting the GLASOD methodology**. ISRIC – International Soil Reference and Information Centre, 1996. Disponível em: < <http://www.isric.org/isric/webdocs/docs/26867final.pdf> > Acesso em 28/06/2015.

OLIVEIRA, M. A. T. Processos erosivos e preservação de áreas de risco de erosão por voçorocas. In: GUERRA, A. J. T. (Org.); SILVA, A. S.(Org.); BOTELHO, R. G. M. (Org.). **Erosão e Conservação dos Solos**: Conceitos, Temas e Aplicações. 2. ed. Rio de Janeiro: Bertran Brasil, 2005. p. 57-99.

PATIL, D. D.; WADHAI, V. M.; GOKHALE, J. A. Evaluation of Decision Tree Pruning Algorithms for Complexity and Classification Accuracy. **International Journal of Computer Applications**, v. 11, n. 2, p. 23-30, 2010.

PERROY, R. L.; BOOKHAGEN, B.; ASNER, G. P.; CHADWICK, O. A. Comparison of gully erosion estimates using airborne and ground-based LiDAR on Santa Cruz Island, California. **Geomorphology**, nº 118, p. 288-300, 2010.

PINHO, C. M. D.; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C. M.; KUX, H. J. H. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. **International Journal of Remote Sensing**, v. 33, nº 19, p. 5973-5995, 2012.

POESEN, J.; NACHTERGALE, J.; VERTSTRAETEN, G.; VALENTIN, C. Gully erosion and environmental change: importance and research needs. **Catena**, nº 50, p. 91-134, 2003.

PRATT, W. K. **Digital Image Processing**. 4th Edition. New Jersey: John Wiley & Sons Inc., 2007.

QUEIROZ, E. **Geomorfologia Ambiental**. Disponível em:  
< <http://profelianageo.no.comunidades.net/geomorfologia-ambiental>> Acesso em: 23/09/2015.

QUINLAN, J. R. **Induction of Decision Trees**. **Machine Learning**, nº 1, p. 81-106, 1986.

QUINLAN, J. R. Simplifying Decision Trees. **International Journal of man-machine studies**, nº 27, p. 211-234, 1987.

QUINLAN, J. R. **C4.5: Programs for machine learning**. USA: Morgan Kaufmann Publishers, 1993.

RAMOS, I. Q., FRANCELINO, M. R.; MAGALHÃES, S. F. C.; OLIVEIRA, C. M. M.; SALAMENE, S. Uso do laser scanner na modelagem de voçorocas do estado do Rio de Janeiro. In: **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.5793.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4th Edition. Germany: Springer, 2006.

RIEGL LASER MEASUREMENTS SYSTEM. **LMS Q-560 – catálogo**. 2010.  
Disponível em: <  
[http://www.riegl.com/uploads/tx\\_pxriegl/downloads/10\\_DataSheet\\_Q560\\_20-09-2010\\_01.pdf](http://www.riegl.com/uploads/tx_pxriegl/downloads/10_DataSheet_Q560_20-09-2010_01.pdf)> Acesso em: 28/06/2015.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence – A modern approach**. Second Edition. USA: Prentice Hall, 2003.

SALOMÃO, F. X. T. Controle e prevenção dos processos erosivos. In: GUERRA, A. J. T. (Org.); SILVA, A. S. (Org.); BOTELHO, R. G. M. (Org.). **Erosão e Conservação dos Solos: Conceitos, Temas e Aplicações**. 2. ed. Rio de Janeiro: Bertran Brasil, 2005. p. 229-267.

SANTOS, E. E.; FARIA, A. L. L. Mapeamento e monitoramento de processos erosivos a partir de imagens Ikonos: Um estudo de caso da área urbana do Município de Queluzito (MG). In: **Anais do XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.5716.



SMPU - SECRETARIA MUNICIPAL DE PLANEJAMENTO URBANO. **Banco de Dados Integrados de Uberlândia – MG**. 2010. Disponível em:  
< [http://www.uberlandia.mg.gov.br/uploads/cms\\_b\\_arquivos/1428.pdf](http://www.uberlandia.mg.gov.br/uploads/cms_b_arquivos/1428.pdf) > Acesso em:  
28/06/2015.

SHARMA, R.; GHOSH, A.; JOSHI, P. K. Decision tree approach for classification of remotely sensed satellite data using open source support. **Journal of Earth System Science**, v. 122, nº 5, p. 1237-1247, 2013.

SHRUTHI, R. B. V.; KERLE, N.; JETTEN, V. Object based gully feature extraction using high spatial resolution imagery. **Geomorphology**, v. 134, p. 260-268, 2011.

SHRUTHI, R. B. V.; KERLE, N.; JETTEN, V. Extracting gully features and its dynamics from high spatial resolution imagery using object based image analysis. In: **Proceedings of the 4th GEOBIA**. Rio de Janeiro-RJ. p. 7-12. 2012.

SHRUTHI, R. B. V.; KERLE, N.; JETTEN, V.; STEIN, A. Object based gully system prediction from medium resolution imagery using Random Forests. **Geomorphology**, v. 216, p. 283-294, 2014.

SHRUTHI, R. B. V.; KERLE, N.; JETTEN, V. ABDELLAH, L.; MACHMACH, I. Quantifying temporal changes in gully erosion areas with object oriented analysis. **Catena**, v. 128, p. 262-277, 2015.

SHRUTHI, R. B. V. **Towards improving gully erosion assessment: coupling object-based image analysis and spatially dynamics erosion modelling**. Tese de doutorado - ITC Faculty of Geo-Information Science and Earth Observation. University of Twente. Netherlands, 2015.

SILVA, E. M.; ASSUNÇÃO, W. L. O clima da cidade de Uberlândia-MG. **Revista Sociedade e Natureza**, v. 16, nº. 30, p. 91-107, 2004.

SILVA, A. S. Análise morfológica dos solos e erosão. In: GUERRA, A. J. T. (Org.); SILVA, A. S. (Org.); BOTELHO, R. G. M. (Org.). **Erosão e Conservação dos Solos: Conceitos, Temas e Aplicações**. 2. ed. Rio de Janeiro: Bertran Brasil, 2005. p. 101-126.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis and Machine Vision**. USA: Thomson, 2008.

TARUVINGA, K. **Gully mapping using Remote Sensing: case study in KwaZulu-Natal, South Africa**. 109 p. Dissertação de Mestrado (Environmental Studies) - University of Waterloo, Ontario-Canadá, 2008.

TOMINAGA, L. K.; SANTORO, J.; AMARAL, R. **Desastres naturais. Conhecer para prevenir**. Instituto Geológico – Secretaria do Meio Ambiente – Governo do Estado de São Paulo. São Paulo, 2009. 196 p.

TRIMBLE. **eCognition Developer 8.8 Reference Book e User Guide**. Germany, 2012.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. Florida – USA: CRC Press, 2009.

VALENTIN, C.; POESEN, J.; YONG, L. Gully erosion: impacts, factors and control. **Catena**, nº 63, p. 132-153, 2005.

VIEIRA, N. M. **Estudo geomorfológico das voçorocas de Franca-SP**. 226 p. Tese (Doutorado) - Faculdade de Filosofia, Ciências e Letras da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Franca, 1978.

VRIELING, A.; RODRIGUES, S. C.; STERK, G. Evaluating erosion from space: a case study near Uberlândia. **Revista Sociedade & Natureza**, Edição Especial, p. 683-696, 2005.

VRIELING, A. **Mapping Erosion from Space**. 139 p. Tese (Doutorado – Escola de Produção de Ecologia e Conservação de Recursos - Wageningen University), 2007.

WANG, T.; HE, F.; ZHANG, A.; GU, L.; WEN, Y.; JIANG, W.; SHAO, H.A. Quantitative Study of Gully Erosion Based on Object-Oriented Analysis Techniques: A Case Study in Beiyanzikou Catchment of Qixia, Shandong, China. **The Scientific World Journal**, v. 2014, p. 1-11, 2014.

WILKINSON, G. G. Results and implications of a study of fifteen years of satellite image classification experiments. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 43, nº 3, pp.433-440, 2005.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining – Practical Machine Learning Tools and Techniques**. Third edition. USA: Morgan Kaufmann, 2011.

WU, X. **Knowledge acquisition from data bases**. 176 p. Tese (Doutorado) – University of Edinburgh, 1993.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 8, p.338-353, 1965.

ZADEH, L. A. Is there a need for fuzzy logic? **Information Sciences**, v. 178, p. 2751–2779, 2008.

ZHANG, K.; CUI, Z. **Airborne LIDAR Data Processing and Analysis Tools**. National Center for Airborne Laser Mapping. 2007.

ZHOU, Z. H.; LI, M. Semi-supervised learning by disagreement. **Knowledge and Information Systems**, v. 24, p. 415-439, 2010.

## DOCUMENTOS CONSULTADOS

BARTELS, M.; WEI, H. Segmentation of LiDAR data using measures of distribution. In: **ISPRS Proceedings of the ISPRS Commission VII Symposium Remote Sensing: 'From Pixels to Processes'**, 2006, Enschede, The Netherlands.

BAATZ, M.; SCHÄPE, A. **Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation**. München. Disponível em: <[http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf)>. Acesso em 16 de novembro de 2012.

BITTENCOURT, G. **Inteligência artificial: Ferramentas e Teorias**. Campinas-SP: Instituto de Computação UNICAMP, 1996.

CHUBEY, M. S.; FRANKLIN, S. E.; WULDER, M. A. Object-based Analysis of Ikonos-2 Imagery for Extraction of Forest Inventory Parameters. **Photogrammetric Engineering & Remote Sensing**, v. 72, nº 4, p. 383-394, 2006.

DALMOLIN, Q.; SANTOS, D. R. **Sistema LASER escanner: Conceitos e Princípios de Funcionamento**. 3ª edição. Curitiba: [Depto Geomática/UFPR], 2004.

FAN, G.; XIA, X. A joint multicontext and multiscale approach to Bayesian image segmentation. **IEEE Transaction on Geoscience and Remote Sensing**, v. 39, nº 2, p. 2680-2688, 2001.

FAYYAD, U. M.; PIATESKY-SHAPIO, G.; SMYTH, P. From data mining to knowledge discovery: an overview. In: FAYYAD, U. **Advances in knowledge discovery and data mining**. Cambridge: AAAI Press, 1996.

FILIN, S.; PFEIFER, N. Segmentation of airborne laser scanning data using a slope adaptive neighborhood. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 60, nº 2, p. 71-80, 2006.

FISCHLER, M. A.; FIRSCHEIN, O. **Intelligence – the eye, the brain, and the computer**. Reading: Addison-Wesley, 1987.

FRANKL, A.; CORNELIS, S. ABRAHA, A.; RIEKE-ZAPP, D.; WULF, A. POESEN, J. Detailed recording of gully morphology in 3D through image-based modelling. **Catena**, v.127, p. 92-101, 2015.

KERSTING, A. B. **Mapeamento de obstáculos sob a faixa de domínio de linhas de transmissão usando um abordagem orientada a objeto, tecnologia LIDAR e câmara digital de pequeno formato**. 173 p. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba-Pr, 2006.

KLIR, G. J.; YUAN, B. **Fuzzy sets and fuzzy logic – Theory and applications**. New Jersey-USA: Prentice Hall, 1995.

PAL, M.; MATHER, P. M. Decision tree based classification of remotely sensed data. In: **22nd Asian Conference on Remote Sensing**, Singapore, 2001.

PINHO, C. M. D. **Análise orientada a objetos de imagens de satélites de alta resolução especial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos-SP**. 176 p. Dissertação (Mestrado em Sensoriamento Remoto) – INPE, São José dos Campos, 2006.

SERATO, D. S.; RODRIGUES, S. C. Avaliação e recuperação da área degradada (voçoroca) no interior da Fazenda Experimental do Glória no município de Uberlândia (MG). **Boletim Goiano de Geografia**, v. 30, nº 2, p. 29-42, 2010.

SCHIMALESKY, V. **Avaliação da qualidade da informação altimétrica derivada da varredura a LASER em uma região coberta por vegetação: um estudo de caso**. 82 p. Dissertação (Mestrado em Ciências Geodésicas) - Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2007.

SCHNEIDER, W.; STEINWENDNER, J. Landcover Mapping by Interrelated Segmentation And Classification Of Satellite Images. **International Archives of Photogrammetry and Remote Sensing**, v. 32, 1999.

SCHNEIDER, A. Monitoring land cover change in urban and peri-urban areas using dense time stacks of Landsat satellite data and a data mining approach. **Remote Sensing of Environment**, v. 124, p. 689-704, 2012.

SITHOLE, G. Segmentation and classification of airborne Laser scanner data. In: **Publications on Geodesy of the Netherlands Commission of Geodesy**, v. 59, 2005.

TSATSIOULIS, C. Expert systems in remote sensing applications. In: **IEEE Geoscience and Remote Sensing Newsletter**, 1993.

VOSSelman, G. Advanced point cloud processing. In: **Photogrammetric Week '09**, Wichmann, 2009. p. 137-146.

WANG, J.; SHAN, J. Segmentation of LiDAR point clouds for building extraction. In: **ASPRS Annual Conference Baltimore**, Maryland, 2009.

WANG, M., TSENG, Y. H. Automatic segmentation of LiDAR data into coplanar point clusters using an octree-based split-and-merge algorithm. **Photogrammetric Engineering and Remote Sensing**, v. 76, nº 4, p. 407-420, 2010.

WANG, F. Improving remote sense image analysis through fuzzy information representation. **Photogrammetric Engineering and Remote Sensing**, v. 56, p.1163-1169,1990.

WEISE, C. A decade of eCognition OBIA: Technical challenges & continual innovation. In: **Palestra proferida no MapGeo.com World Tour 2012**. Budapeste, Hungria, 2012.

WILKINSON, L. **Classification and Regression Trees**. Disponível em:  
<[http://cda.psych.uiuc.edu/multivariate\\_fall\\_2013/systat\\_cart\\_manual.pdf](http://cda.psych.uiuc.edu/multivariate_fall_2013/systat_cart_manual.pdf)> Acesso  
em 28/06/2015.

ZHANG, J. X.; LIN, X. G. SVMS-based classification of segmented airborne LiDAR point clouds in urban areas. **Proceedings of the 4<sup>th</sup> GEOBIA**, 2012 - Rio de Janeiro - Brasil. p.001.

## APÊNDICE - REGISTRO DOS DADOS ESPECTRAIS E ALTIMÉTRICOS DA ÁREA DE ESTUDO A1

O registro da imagem Ikonos em relação à imagem de intensidade foi realizado com base na seleção de dez pontos de controle, cujas localizações são ilustradas na figura 1.1. Pela figura, é possível perceber que a distribuição dos pontos não foi homogênea, em virtude de tratar-se de ambiente rural no qual se torna difícil encontrar pontos homólogos. Vale ressaltar que as características espectrais de uma imagem de intensidade são diferentes das de uma imagem no espectro óptico, o que dificulta a seleção de pontos homólogos identificáveis em ambas as imagens. A figura 1.2 mostra os pontos de controle, em detalhe, evidenciando estas diferenças.

A tabela 1.1 apresenta os erros obtidos, todos inferiores a 2 pixels (ou a 2 metros, neste caso, conforme critério pré-estabelecido para aceitar o registro). X e Y são as posições em coluna e linha, respectivamente, na imagem de referência. X<sub>est</sub> e Y<sub>est</sub> são as coordenadas estimadas para o pós-registro da imagem a ser registrada. Ex e Ey são as diferenças nas coordenadas X e Y entre as coordenadas.

TABELA 1.1 – ERROS DO REGISTRO PARA OS PONTOS DE CONTROLE

Pto	X	X <sub>est</sub>	Ex	Ex <sup>2</sup>	Y	Y <sub>est</sub>	Ey	Ey <sup>2</sup>	Erro
1	894,75	895,0493	0,2993	0,08958	1382,00	1382,7390	0,7390	0,546121	0,7973
2	234,00	233,4130	-0,5870	0,344569	136,75	136,2914	-0,4586	0,210314	0,7449
3	863,86	864,1207	0,2607	0,067964	1142,07	1142,8227	0,7527	0,566557	0,7965
4	97,75	97,3549	-0,3951	0,156104	1176,25	1175,3307	-0,9193	0,845112	1,0006
5	978,25	978,0282	-0,2218	0,049195	339,75	339,9182	0,1682	0,028291	0,2784
6	904,00	904,4013	0,4013	0,161042	395,00	395,2968	0,2968	0,08809	0,4992
7	1704,00	1703,7336	-0,2664	0,070969	1021,83	1020,5161	-1,3139	1,726333	1,3407
8	238,75	239,3227	0,5727	0,327985	201,33	201,6875	0,3575	0,127806	0,6751
9	1701,75	1700,8847	0,8653	0,748744	1017,00	1016,5982	-0,4018	0,161443	0,9541
10	1652,00	1652,8017	0,8017	0,642723	979,00	979,7794	0,7794	0,607464	1,1181

FONTE: A AUTORA (2015)

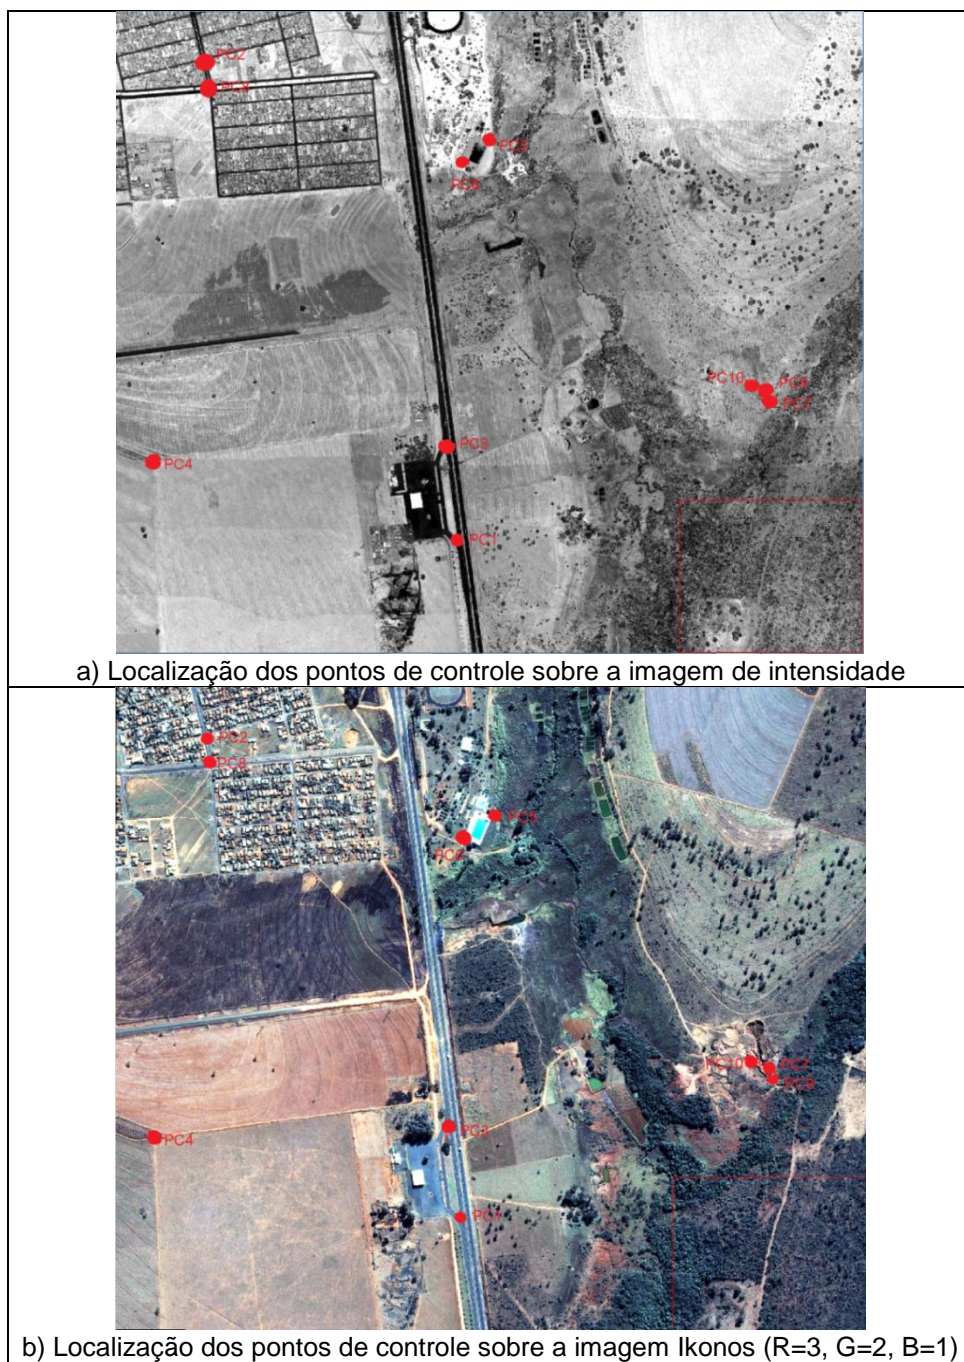


FIGURA 1.1 – DISTRIBUIÇÃO DOS PONTOS DE CONTROLE  
FONTE: A AUTORA (2015)



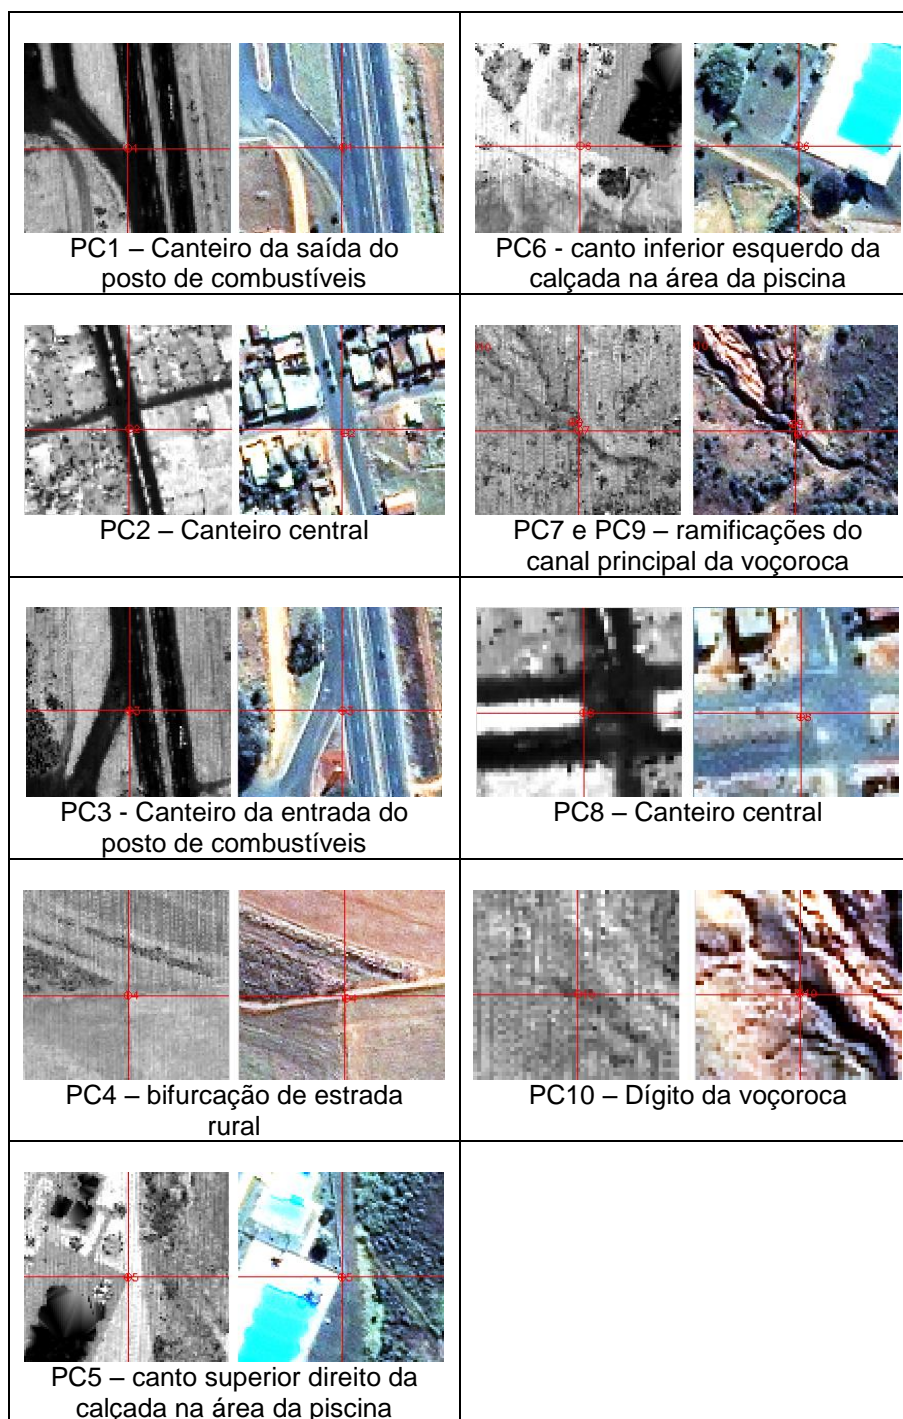


FIGURA 1.2 – PONTOS DE CONTROLE  
 FONTE: A AUTORA (2015)




FIGURA 1.3 – ERROS NAS COORDENADAS ESTIMADAS PARA OS PONTOS DE CONTROLE  
FONTE: A AUTORA (2015)

$$Ex = X_{est} - X$$

$$Ey = Y_{est} - Y$$

$$\text{Erro} = \sqrt{Ex^2 + Ey^2}$$

$$\text{Erro total} = \sqrt{\frac{\sum(Ex^2 + Ey^2)}{10}}$$

sendo:

Ex e Ey = erro em X e erro em Y

Xest e Yest = X e Y estimados para pós-registro

X e Y = coordenadas na imagem anterior ao registro

Erro = erro do ponto

Erro total = erro calculado para o conjunto de pontos

O erro máximo em X (Ex) foi de 0,8653m e em y (Ey) foi de -1,3139m. O erro total foi de 0,869848m, inferior a um pixel.

Para a validação do registro, foram selecionados 12 pontos de verificação, ilustrados nas figuras 1.4 e 1.5.

As coordenadas linha e coluna de cada ponto de verificação foram determinadas na imagem de intensidade e na imagem Ikonos registrada. A tabela 1.2 apresenta os resultados obtidos. Para 3 pontos (25% do total) obteve-se erro superior a 2 pixels (igual a 3). Para 75% do conjunto de dados obteve-se erro igual ou inferior a 2 pixels.



a) Localização dos pontos de verificação sobre a imagem de intensidade



b) Localização dos pontos de verificação sobre a imagem Ikonos

FIGURA 1.4 – DISTRIBUIÇÃO DOS PONTOS DE VERIFICAÇÃO  
FONTE: A AUTORA (2015)



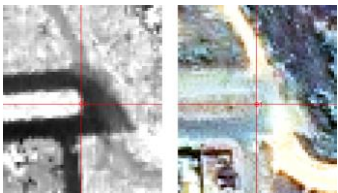
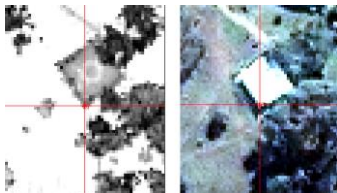
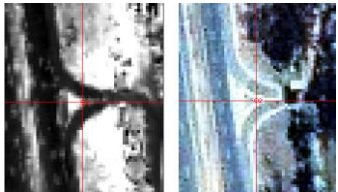
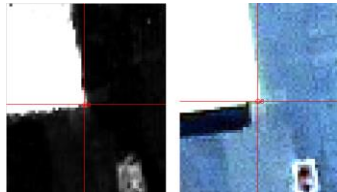
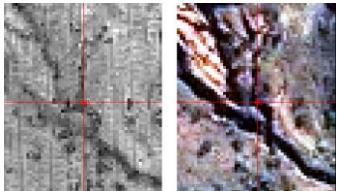
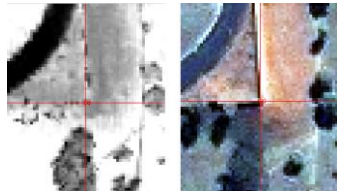
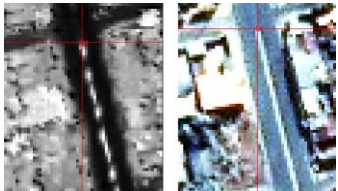
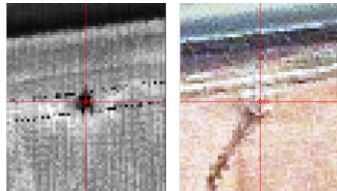
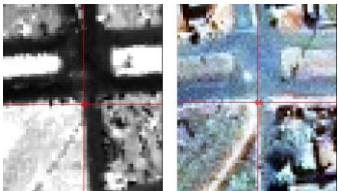
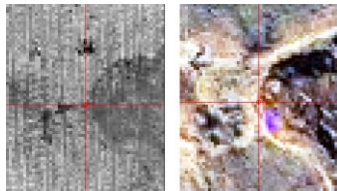
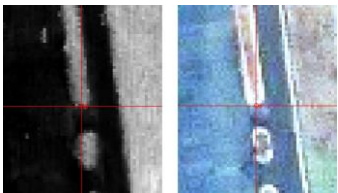
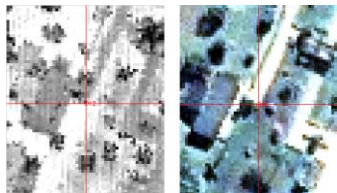
 <p>PV1 – Canteiro central na rua</p>	 <p>PV7 - Clube</p>
 <p>PV2 – Canteiro na rodovia</p>	 <p>PV8 – Cobertura no posto de combustíveis</p>
 <p>PV3 – Canal voçoroca</p>	 <p>PV9 – Muro do campo de futebol</p>
 <p>PV4 – Canteiro central na rua</p>	 <p>PV10 – Poste de iluminação</p>
 <p>PV5 – Canto da quadra</p>	 <p>PV11 – Borda da cabeceira da voçoroca</p>
 <p>PV6 – Canteiro no posto de combustíveis</p>	 <p>PV12 – Calçada no clube</p>

FIGURA 1.5 – PONTOS DE VERIFICAÇÃO  
 FONTE: A AUTORA (2015)

TABELA 1.2 – ERROS DO REGISTRO PARA OS PONTOS DE VERIFICAÇÃO  
 FONTE: A AUTORA (2015)

Ponto	coluna			linha		
	Intensidade	Ikonos registrada	Erro  (pixel)	Intensidade	Ikonos registrada	Erro  (pixel)
1	675	676	1	167	168	1
2	757	757	0	71	72	1
3	1697	1698	1	1007	1008	1
4	205	205	0	14	11	3
5	245	245	0	214	212	2
6	844	845	1	1256	1256	0
7	897	897	0	212	211	1
8	802	801	1	1295	1292	3
9	912	912	0	55	58	3
10	384	384	0	881	881	0
11	1635	1636	1	895	895	0
12	898	900	2	335	336	1